



ISSN: 1646-9895

Revista Ibérica de Sistemas e Tecnologias de Informação
Revista Ibérica de Sistemas y Tecnologías de Información

J u n h o 2 4 • J u n e 2 4



©RISTI 2024 <http://www.risti.xyz>

Nº 54

Edição / Edición

Nº 54, 06/2024

Tiragem / Tirage: 1000

Preço por número / Precio por número: 17,5€

Subscrição anual / Suscripción anual: 30€ (2 números)

ISSN: 1646-9895

Depósito legal:

Indexação / Indexación

Academic Journals Database, CiteFactor, Dialnet, DOAJ, DOI, EBSCO, GALE, IndexCopernicus, Index of Information Systems Journals, ISI Web of Knowledge, Latindex, ProQuest, QUALIS, SciELO, SCImago, Scopus, SIS, Ulrich's.

Publicação / Publicación

RISTI – Revista Ibérica de Sistemas e Tecnologias de Informação

Pc. 9 de Abril, nº 26, 4200-422 Porto, Portugal

E-mail: aistic@gmail.com

Web: <http://www.risti.xyz>

Director

Álvaro Rocha, ISEG, Universidade de Lisboa, PT

Coordenadores da Edição / Coordinadores de la Edición

Artur Rocha, University of Essex, UK

Rita Amaral, ITMA, PT

Álvaro Rocha, ISEG, Universidade de Lisboa, PT

Conselho Editorial / Consejo Editorial

Abel Méndez, Instituto Tecnológico de Costa Rica, CR

Alejandro Peña, Universidad EAFIT, CO

Alma Gómez-Rodríguez, Universidade de Vigo, ES

Ana Rita Calvão, ESTGA, Universidad de Aveiro, PT

Ania Cravero, Universidad de La Frontera, CL

António Abreu Silva, ISCAP, Instituto Politécnico do Porto, PT

Antonio Garcia, Universidad de Santiago de Compostela, ES

António Godinho, ISEC, Instituto Politécnico de Coimbra, PT

Antonio Jiménez-Martín, Universidad Politécnica de Madrid, ES

Arturo J. Méndez, Universidad de Vigo, ES

August Climent, Ramon LLull University, ES

Beatriz Rodríguez, Universidad de la Republica, UY

Borja Bordel, Universidad Politécnica de Madrid, ES

Brenda L. Flores-Rios, Universidad Autónoma de Baja California, MX

Bruno Miguel Ferreira Gonçalves, Instituto Politécnico de Bragança, PT

Carlos Alexandre Silva, Instituto Federal de Minas Gerais, BR

Carlos Carreto, Instituto Politécnico da Guarda, PT

Carlos Morais, Instituto Politécnico de Bragança, PT

Carlos Rompante Cunha, UNIAG & CeDRI & Instituto Politécnico Bragança, PT

Carlos Vaz de Carvalho, Instituto Politécnico do Porto, PT

Célio Marques, Instituto Politécnico de Tomar, PT

Ciro Martins, Universidade do Algarve, PT

Cristina Caridade, Instituto Politécnico de Coimbra, PT

Daniel Polónia, Universidade de Aveiro, PT

Dante Carrizo, Universidad de Atacama, CL
Edwin Cedeño Herrera, Universidad de Panamá, PA
Fábio Marques, ESTGA, Universidade de Aveiro, PT
Felipe Vasquez, Universidad de La Frontera, CL
Fernando Moreira, REMIT, IJP, Universidade Portucalense & IEETA,
Universidade de Aveiro, PT
Fernando Paulo Belfo, Coimbra Business School – ISCAC,
Polytechnic Institute of Coimbra, PT
Fernando Ribeiro, Instituto Politécnico de Castelo Branco, PT
Fernando Bandeira, PT
Filipe Cardoso, Instituto Politécnico de Viseu, PT
Flor Gomes de María Sánchez Aguirre, Universidad César Vallejo, PE
Francisco Javier Lena-Acebo, Universidad de Cantabria, ES
Gabriel Guerrero-Contreras, Universidad de Cádiz, ES
Gerardo González Filgueira, Universidade da Coruña, ES
Gloria Valencia, Universidad de las Fuerzas Armadas, EC
Guilllhermo Davila, Universidad de Lima, PE
Hélder Gomes, Universidade de Aveiro, PT
Helder Zagalo, Universidade de Aveiro, PT
Hélia Guerra, Universidade dos Açores, PT
Henrique Gil, Instituto Politécnico de Castelo Branco, PT
Henrique S. Mamede, Universidade Aberta, Portugal
Inês Domingues, ISEC, Instituto Politécnico de Coimbra, PT
Isaias Bianchi, Universidade Federal de Santa Catarina, BR
Isidro Navarro, Universidad Politécnica de Cataluña, ES
Ismael Etxeberria-Agiriano, Universidad del País Vasco, ES
Ivan Garcia, Universidad Tecnológica de la Mixteca, MX
Jeimy Cano, Universidad de los Andes, CO
João Emílio Almeida, ISTECS - Porto, PT
João Paulo Ferreira, Instituto Politécnico de Coimbra, PT
Joao Roberto de Toledo Quadros, CEFET/RJ, BR
Joao Tavares, Universidade do Porto, PT
Joaquim Reis, ISCTE - Instituto Universitário de Lisboa, PT

Jorge Eduardo Ibarra Esque, Universidad Autónoma de Baja California, MX
Jorge Hochstetter, Universidad de La Frontera, CL
José Álvarez-García, Universidad de Extremadura, ES
Jose Felipe Cocon Juarez, Universidad Autónoma del Carmen, MX
José Lousado, Instituto Politécnico de Viseu, PT
José Luis Pastrana Brincones, Universidad de Málaga, ES
Jose M. Molina, Universidad Carlos III de Madrid, ES
José Ribeiro, Politécnico de Leiria, PT
Jose Silvestre Silva, Academia Militar, PT
Josep Maria Marco-Simó, Universitat Oberta de Catalunya, ES
Juan Angel Contreras Vas, Universidad de Extremadura, ES
Juan M. Santos-Gago, Universidad de Vigo, ES
Juan Pablo DAmato, Universidad Nacional del Centro de la
Provincia de Buenos Aires, AR
Leila Weitzel, Universidade Federal Fluminense, BR
Leonardo Bermón Angarita, Universidad Nacional de Colombia, CO
Lilia Muñoz, Universidad Tecnológica de Panamá, PA
Lucila Romero, Universidad Nacional del Litoral, AR
Luis Álvarez Sabucedo, Universidad de Vigo, ES
Luis Enrique Sánchez Crespo, Universidad de Castilla-la Mancha, ES
Luisa María Romero-Moreno, Universidad Sevilla, ES
Luz María Hernández Cruz, Universidad Autónoma de Campeche, MX
Luz Sussy Bayona Oré, Universidad Nacional Mayor de San Carlos, PE
Marcelo Marciszack, Universidad Tecnológica Nacional, AR
Marcelo Zambrano Vizueté, Universidad Técnica Del Norte
Marco Painho, NOVA IMS, PT
Margarita Ramirez Ramirez, Universidad Autónoma de Baja California, MX
Maria Cristina Marcelino Bento, UNIFATEA, BR
María de la Cruz del Río-Rama, Universidad de Vigo, ES
Maria de los Milagros Gutierrez, Universidad Tecnológica Nacional, AR
Maria do Rosário Bernardo, Universidade Aberta, PT
Maria Hallo, Escuela Politécnica Nacional, EC
Maria João Ferreira, Universidade Portucalense, PT

Maria João Gomes, Universidade do Minho, PT
Maria Sousa, ISCTE - Instituto Universitário de Lisboa, PT
Marisol B. Correia, ESGHT - Universidade do Algarve & CiTUR, PT
Maristela Holanda, Universidade de Brasília, BR
Martin Llamas Nistal, Universidad de Vigo, ES
Miguel Casquilho, Universidade de Lisboa, PT
Miguel Ramón González Castro, Centro Tecnológico Aimen, ES
Mirna Ariadna Muñoz Mata, CIMAT, MX
Nelson Rocha, Universidade de Aveiro, PT
Nuno Melão, Instituto Politécnico de Viseu, PT
Nuno Ribeiro, Universidade Fernando Pessoa, Portugal
Patricia Dias, Universidade do Estado de Minas Gerais, BR
Paula Prata, Universidade da Beira Interior, PT
Paulo Martins, Universidade de Trás-os-Montes e Alto Douro, PT
Paulo Pinto, Universidade Nova de Lisboa, PT
Paulo Rurato, Universidade Fernando Pessoa, Portugal
Pedro Araújo, Universidade da Beira Interior, PT
Pedro R. Palos- Sanchez, Universidad de Sevilla, ES
Pedro Sanz-Angulo, Universidad de Valladolid, ES
Pedro Sobral, Universidade Fernando Pessoa, Portugal
Pedro Sousa, Universidade do Minho, Portugal
René Faruk Garzozzi-Pincay, Universidad Estatal Península de Santa Elena, EC
Ruben Pereira, ISCTE – Instituto Universitário de Lisboa, PT
Rui Pedro Marques, Universidade de Aveiro, PT
Rui Silva Moreira, Universidade Fernando Pessoa, PT
Samuel Sepúlveda, Universidad de La Frontera, CL
Santiago Raul Gonzales Sanches, Universidad Cesar Vallejo, PE
Sara Balderas-Díaz, Universidad de Cádiz, ES
Sergio Araya Guzmán, Universidad del Bío-Bío, CL
Sergio F. Lopes, Universidade do Minho, PT
Sergio Gálvez Rojas, Universidad de Málaga, ES
Solange N Alves-Souza, Universidade de São Paulo, BR
Telmo Silva, DigiMedia, Universidade de Aveiro, PT

Thiago Dias, Centro Federal de Educação Tecnológica de Minas Gerais, BR
Verónica Vasconcelos, Polytechnic Institute of Coimbra, PT
Vitor Carvalho, Instituto Politécnico do Cávado e do Ave, PT
Vitor Santos, Universidade Nova de Lisboa - NOVA IMS, PT
Wagner Tanaka Botelho, Universidade Federal do ABC, BR
Yamid Hernández Julio, Universidad del Sinú, CO

Índice / Index

EDITORIAL

Novas Tendências em Sistemas e Tecnologias de Informação	1
<i>Artur Rocha, Rita Amaral, Álvaro Rocha</i>	

ARTIGOS / ARTICULOS / ARTICLES

Uma revisão sistemática de modelos de <i>machine learning</i> aplicados em operações financeiras de cobranças de dívidas.....	5
<i>Jonnathan de Almeida Martins, Arnaldo Rabello de Aguiar Vallim-Filho</i>	

Aumento da maturidade de equipes SCRUM de desenvolvimento de software.....	22
<i>Klauren Godoi Araújo Camargo, Napoleão Verardi Galegale</i>	

Inteligencia artificial en el estudio del uso de escaneo cerebral en la implementación en usuarios neurodivergentes.....	39
<i>Mateo Dwyer</i>	

Los sistemas de información y su influencia en las estrategias ambientales y el rendimiento organizacional.....	52
<i>Enrique Ismael Meléndez Ruiz, Demian Abrego Almazán, José Melchor Medina Quintero</i>	

Sistema Inteligente de Gestión de Semáforos en Tiempo Real.....	69
<i>Yim Isaias Apestequi Florentino, Hugo Esteban Caselli Gismondi</i>	

Sistema de Identificação de Expressões Faciais Básicas em um Editor de Texto Coletivo	88
<i>André Gabriel Alves, Michele Alda Rosso Guizzo, Alexandra Lorandi, Patricia Alejandra Behar</i>	

Prototipo de un sistema de seguimiento de boyas Lagrangianas para Oceanografía observacional	104
<i>M. Carmen Clemente, Álvaro Hernández-Romero, Simone Sammartino, Francisco Criado-Aldeanueva y Pablo Otero</i>	

Uma Aplicação para Explicabilidade de Predições de um SVM em Tweets de COVID-19.....	121
<i>Ivo de Abreu Araújo, Renato Hidaka Torres, Nelson Cruz Sampaio Neto</i>	

Novas Tendências em Sistemas e Tecnologias de Informação

New Trends in Information Systems and Technologies

Artur Rocha¹, Rita Amaral², Álvaro Rocha³

arturrocha05@gmail.com; ritanoamaral@gmail.com; amr@iseg.ulisboa.pt

¹ University of Essex, Wivenhoe Park, Colchester CO4 3SQ, Reino Unido.

² ITMA, Praça de Nove de Abril, 26, 4200-422 Porto, Portugal.

³ ISEG, Universidade de Lisboa, Rua Miguel Lupi 20, 1200-725 Lisboa, Portugal.

DOI: 10.17013/risti.54.1-4

1. Introdução

As novas tendências em sistemas e tecnologias de informação estão a moldar o futuro da inovação digital e da transformação das organizações. Entre as principais, destaca-se a inteligência artificial (IA), que continua a evoluir com aplicações avançadas de aprendizagem de máquina, processamento de linguagem natural e automação inteligente. A computação em nuvem e a Edge Computing estão a redefinir a infraestrutura de TI, permitindo maior escalabilidade e eficiência. Além disto, a tecnologia Blockchain está a ganhar destaque pela sua capacidade de fornecer segurança e transparência em transações digitais. A Internet das Coisas (IoT) está a expandir a conectividade entre dispositivos, possibilitando novos modelos de negócio e serviços personalizados. Estas tendências, juntamente com a crescente importância da cibersegurança, estão a transformar o panorama das TI, exigindo das organizações uma adaptação constante e uma visão estratégica para capitalizar estas inovações.

A edição número 54 da RISTI (Revista Ibérica de Sistemas e Tecnologias de Informação) apresenta uma coleção de artigos que refletem tendências recentes e emergentes em sistemas e tecnologias de informação. Nesta edição, publicamos os 8 melhores artigos selecionados de entre 153 submissões oriundas de 16 países - a que corresponde uma

exigentíssima taxa de aceitação de 5,2% -, que oferecem contribuições para o avanço do conhecimento e prática na área. Cada artigo foi cuidadosamente revisto por pelo menos dois membros do Conselho Editorial.

2. Estrutura e Conteúdos da Edição

Esta edição número 54 da RISTI organiza-se neste editorial e nos oito artigos selecionados, que são apresentados resumidamente a seguir:

O primeiro artigo, com o título *“Uma Revisão Sistemática de Modelos de Machine Learning Aplicados em Operações Financeiras de Cobranças de Dívidas”*, aborda a aplicação de técnicas de Machine Learning (ML) nas operações de cobrança de dívidas no Brasil, especialmente num contexto de altas taxas de inadimplência exacerbadas pela pandemia. Utilizando a metodologia PICO, foram identificados 41 documentos, dos quais 11 passaram por revisão sistemática. Os objetivos dos estudos analisados incluem previsão de inadimplência, personalização de estratégias de cobrança, otimização das ações de recuperação de dívidas e previsão de recuperação de crédito. Os principais algoritmos utilizados são Decision Tree, Logistic Regression, Random Forest, Naive Bayes, Artificial Neural Network e Deep Learning. A investigação revelou que a aplicação de ML nessa área ainda é limitada, mas possui grande potencial para avanços significativos.

O segundo artigo, intitulado *“Aumento da Maturidade de Equipes SCRUM de Desenvolvimento de Software”*, investiga a adoção de metodologias ágeis numa grande instituição financeira brasileira. Utilizando a metodologia Design Science Research Methodology (DSRM), o estudo desenvolve e avalia um roadmap denominado RPATS (Roadmap de Práticas Ágeis para Scrum Teams) para aprimorar a maturidade ágil das equipas Scrum. O RPATS foi validado quanto à sua usabilidade, factibilidade e utilidade através de demonstrações com equipas de desenvolvimento e um grupo focal de especialistas em agilidade. Os resultados indicam que o roadmap é eficaz para aumentar a maturidade ágil, sendo considerado fácil de usar e útil pelas equipas e especialistas envolvidos. O artigo conclui destacando as contribuições do RPATS para a prática ágil nas empresas e sugere investigações futuras para expandir a aplicação do roadmap em outros contextos.

O terceiro artigo, cujo título é *“Inteligencia Artificial en el Estudio del uso de Escaneo Cerebral en la Implementación en Usuarios Neurodivergentes”*, investiga a eficácia do uso de inteligência artificial para o reconhecimento de padrões elétricos cerebrais no diagnóstico de transtornos mentais. A investigação, de carácter quanti-cualitativo, realizou uma revisão sistemática da literatura, identificando que a combinação de escaneamento cerebral e inteligência artificial pode proporcionar uma deteção mais rápida, simples e objetiva de transtornos mentais, incluindo em idades mais jovens. O estudo destaca a necessidade de desenvolvimento contínuo dessas tecnologias e a capacitação de profissionais para a sua aplicação, sugerindo que essas ferramentas serão indispensáveis no futuro próximo para a psicologia médica. Conclui-se que, embora promissoras, estas tecnologias devem ser usadas como ferramentas complementares ao diagnóstico humano.

O quarto artigo, designado “*Los Sistemas de Información y su Influencia en las Estrategias Ambientales y el Rendimiento Organizacional*”, analisa como os sistemas de informação verdes (SIV) influenciam as estratégias ambientais e o desempenho organizacional das empresas manufatureiras mexicanas. Utilizando um modelo hierárquico de segundo nível e modelação de equações estruturais com mínimos quadrados parciais (PLS-SEM), o estudo quantitativo recolheu dados de 99 gestores de empresas através de um questionário. Os resultados mostram que os SIV desempenham um papel crucial no crescimento das empresas ao melhorar as suas operações, reduzir custos e diminuir a emissão de poluentes, contribuindo significativamente tanto para o desempenho económico quanto ambiental. Contudo, as estratégias ambientais, embora apresentem um impacto positivo, não mostraram uma relação significativa com o desempenho organizacional. O estudo conclui que, embora os SIV sejam eficazes para melhorar o desempenho operacional e reduzir a pegada ambiental, é necessário um maior envolvimento e conscientização das empresas sobre os benefícios das estratégias ambientais.

O quinto artigo, com o título “*Sistema Inteligente de Gestión de Semáforos en Tiempo Real*”, propõe um sistema inteligente para a gestão de semáforos em interseções rodoviárias, ajustando-se às condições reais de tráfego, como velocidade e densidade de veículos. Utilizando um algoritmo heurístico e técnicas de inteligência artificial, como o YOLOv4 para a deteção de veículos e o Método de Detección de Intrusiones (IDM) para medir a velocidade, o sistema visa otimizar o tempo dos ciclos semaforicos. Em testes com 15.000 cenários simulados, o sistema demonstrou uma redução de 18,3% no tempo de ciclo, melhorando a eficiência de 39 ciclos/hora para 47 ciclos/hora em comparação com semáforos tradicionais de tempos fixos. O estudo conclui que a implementação deste sistema pode significativamente reduzir o tempo de espera dos veículos e melhorar o fluxo de tráfego em áreas urbanas congestionadas.

O sexto artigo, intitulado “*Sistema de Identificação de Expressões Faciais Básicas em um Editor de Texto Coletivo*”, apresenta o desenvolvimento de uma ferramenta para reconhecimento de emoções básicas de estudantes durante a produção textual, utilizando técnicas de visão computacional. A funcionalidade foi implementada no Editor de Texto Coletivo (ETC), proporcionando uma janela de deteção de expressões faciais em tempo real e uma página de relatórios que armazena dados das expressões ao longo do tempo. O estudo, dividido em quatro etapas (fundamentação teórica, escolha de ferramentas e bibliotecas, desenvolvimento da funcionalidade, e testes com especialistas), concluiu que é possível recolher informações sobre as emoções básicas dos alunos, como alegria, tristeza, raiva, medo, nojo e surpresa, para apoiar práticas pedagógicas e aumentar o engajamento dos alunos. Os resultados indicam que, apesar das distorções causadas por fatores externos, a ferramenta pode ser uma valiosa aliada na personalização do ensino, proporcionando aos professores uma visão mais profunda dos aspetos afetivos dos estudantes durante o processo de aprendizagem.

O sétimo artigo, cujo título é “*Prototipo de un Sistema de Seguimiento de Boyas Lagrangianas para Oceanografía Observacional*”, descreve o desenvolvimento de um sistema de posicionamento para validar modelos numéricos de predição de resíduos sólidos nas costas. Utilizando tecnologia de radiofrequência LoRa, o sistema traça

as trajetórias de boias Lagrangianas equipadas com recetores GNSS, permitindo a extração de dados em tempo real. Composto por boias de deriva superficial e recetores em embarcações, o sistema visa não apenas validar modelos hidrodinâmicos, mas também fornecer uma metodologia escalável para estudos oceanográficos. Os testes demonstraram a eficácia do sistema em termos de autonomia, precisão e capacidade de transmissão de dados, destacando o seu potencial para aprimorar a observação e a gestão ambiental costeira.

Por último, o oitavo artigo, designado “*Uma Aplicação para Explicabilidade de Predições de um SVM em Tweets de COVID-19*”, apresenta uma aplicação web que utiliza um modelo de Support Vector Machine (SVM) para classificar sentimentos em tweets sobre a COVID-19, integrando o framework LIME para explicar de forma interativa as decisões do modelo. Com uma acurácia inicial de 79%, o estudo revelou que o SVM tende a falhar ao associar testes positivos de COVID-19 a sentimentos positivos e confunde termos relacionados às variantes do vírus devido à falta de representatividade na base de dados. Através da explicabilidade proporcionada pelo LIME, foi possível identificar e corrigir essas falhas, melhorando a acurácia do modelo para 81% ao incluir stopwords como “not” e “no”. O artigo conclui que a explicabilidade pode aumentar a transparência e a precisão de modelos de aprendizagem de máquina, especialmente em contextos de processamento de linguagem natural, destacando a necessidade de bases de dados atualizadas e representativas.

3. Agradecimentos

A edição número 54 da RISTI oferece uma visão abrangente de tendências atuais e futuras em sistemas e tecnologias de informação. A diversidade dos temas abordados reflete a complexidade e a dinâmica da área científica, sublinhando a importância da investigação contínua e da inovação. Agradecemos aos autores pelas suas contribuições valiosas e aos revisores pelo seu trabalho diligente para garantir a qualidade dos artigos publicados.

Esperamos que os leitores encontrem nesta edição uma fonte rica de conhecimento e inspiração para as suas práticas e estudos. Desejamos a todos uma leitura proveitosa e estimulante.

Para finalizar, agradecemos às associações científicas AISTI e ITMA, promotoras da RISTI, assim como às Bases de Dados de Revistas Académicas como Academic Journals Database, Dialnet, DOI, EBSCO, GALE, Google Scholar, IndexCopernicus, Information Systems Journal, Latindex, ProQuest, QUALIS, SciELO, SCImago, Scopus, SIS, Ulrich’s e Web of Science, entidades que contribuem para que a RISTI seja uma revista científica de referência internacional.

Uma revisão sistemática de modelos de *machine learning* aplicados em operações financeiras de cobranças de dívidas

Jonnathan de Almeida Martins¹, Arnaldo Rabello de Aguiar Vallim-Filho¹

jam0604@gmail.com; arnaldo.vallim@mackenzie.br

¹ Universidade Presbiteriana Mackenzie, São Paulo, Brasil

DOI: 10.17013/risti.54-5-21

Resumo: O Brasil enfrenta altas taxas de inadimplência, devido em parte à pandemia, levando à busca de novas estratégias de cobranças de dívidas. O *Machine Learning* (ML), empregado com sucesso em inúmeras áreas, é aliado para elevar a eficácia dessas operações. Este artigo busca apresentar um panorama atual das pesquisas sobre aplicações de ML nas operações de cobrança de dívidas, por meio de uma Revisão Sistemática da Literatura. Foi utilizada a metodologia PICO, identificando inicialmente 41 documentos, dos quais 11 passaram por revisão sistemática. Os resultados mostraram quatro objetivos buscados pelos estudos: previsão de inadimplência, personalização das estratégias de cobrança, otimização das ações de recuperação de dívidas e previsão de recuperação de crédito. E os principais algoritmos utilizados foram *Decision Tree*, *Logistic Regression*, *Random Forest*, *Naive Bayes*, *Artificial Neural Network* e *Deep Learning*. Os resultados revelaram que ML é ainda pouco explorado nessa área, oferecendo potencial para avanços substanciais das pesquisas.

Palavras-chave: Cobrança de dívidas; Aprendizagem de máquina; Operações financeiras; Revisão sistemática de literatura.

A systematic review of machine learning models applied in debt collection operations

Abstract: Brazil is facing high default rates, due in part to the pandemic, leading to the search for new debt collection strategies. Machine Learning (ML), successfully used in numerous areas, is an ally to increase the effectiveness of these operations. This article seeks to present a current overview of research on ML applications in debt collection operations, through a Systematic Literature Review. The PICO methodology was used, initially identifying 41 documents, of which 11 underwent systematic review. The results showed four objectives pursued by the studies: default prediction, personalization of collection strategies, optimization of debt recovery actions and credit recovery prediction. And the main algorithms used were *Decision Tree*, *Logistic Regression*, *Random Forest*, *Naive Bayes*, *Artificial Neural Network* and *Deep Learning*. The results revealed that ML is still little explored in this area, offering potential for substantial research advances.

Keywords: Debt collection; Machine learning; Financial operations, Systematic literature review.

1. Introdução

No contexto econômico contemporâneo do Brasil, a inadimplência se destaca como uma preocupação persistente e de significativa amplitude. De acordo com Serasa (2023), que apresenta o Mapa da Inadimplência no Brasil, observa-se uma realidade alarmante: mais de 71 milhões de cidadãos brasileiros enfrentam a inadimplência, o que corresponde a aproximadamente 43% da população (Serasa, 2023). Essa estatística impactante, além de espelhar uma realidade econômica complexa e desafiadora, evidencia a imperativa necessidade de aprofundar nosso entendimento sobre a questão e aprimorar a eficácia das estratégias de recuperação de dívidas.

A inadimplência é caracterizada como a falta de pagamento ou o não-cumprimento de um contrato ou cláusula, ou seja, a não-satisfação da obrigação no prazo determinado (Sehn e Carlini Junior, 2007). A inadimplência e a cobrança de dívidas estão ligadas em um ciclo financeiro envolvendo credores e devedores, e nesse contexto tem-se a operação de cobranças de dívidas visando recuperar valores em débito (Tambellini, 2021). Essas operações têm evoluído significativamente, impulsionado por diversos fatores econômicos, sociais e tecnológicos. Inicialmente ancoradas em métodos tradicionais, como o envio de correspondências e telefonemas diretos, as estratégias de cobrança têm gradualmente migrado para abordagens mais sofisticadas devido ao avanço tecnológico e à crescente digitalização (Tambellini, 2021).

A inadimplência transcende a mera questão do cumprimento de obrigações financeiras, convertendo-se em um problema de relevância crítica que afeta não apenas a economia do país, mas também a vida cotidiana de milhões de brasileiros. E neste cenário observa-se uma crescente demanda por parte das instituições financeiras em busca de soluções eficazes para a gestão de dívidas e a recuperação de crédito, assim como a adoção de medidas governamentais de apoio, exemplificado pelo programa “Desenrola Brasil”. Oficialmente lançado pelo Governo Federal em junho de 2023 e posteriormente regulamentado pelas Portarias Normativas MF Nº 634/23 (Brasil, 2023a) e MF Nº 733/23 (Brasil, 2023b), este programa representa uma iniciativa significativa para enfrentar o problema da inadimplência, buscando facilitar a renegociação de dívidas e estimular o potencial de consumo da população. Essa abordagem conjunta reflete a urgente necessidade de ações coordenadas e eficazes diante dos desafios econômicos atuais.

Entretanto, além das medidas macroeconômicas e das políticas governamentais, é crucial considerar a inovação e a adaptação de estratégias específicas para a gestão da inadimplência em um mundo cada vez mais influenciado pela tecnologia e pelos avanços na ciência de dados. Conforme observado por Schwab (2018), a Inteligência Artificial (IA) representa uma das características definidoras da quarta revolução industrial, com avanços notáveis ocorridos nos últimos anos. Além do aumento na capacidade de processamento dos computadores como um dos seus impulsionadores, o crescimento exponencial de dados, também conhecido como o fenômeno “big data”, tem contribuído para esse avanço. Ele alavancou uma subcategoria da IA, o Aprendizado de Máquina

ou *Machine Learning* (ML). A expressão “*machine learning*”, atribuída a Samuel (1959), delinea a área que confere a sistemas computacionais a habilidade de adquirir conhecimento de maneira autônoma, sem requerer programação explícita.

Esse aprendizado do algoritmo pode se dar segundo diferentes estratégias (Russel e Norvig, 2022):

- **Aprendizado Supervisionado (Supervised Learning):** Algoritmos são treinados em conjuntos de dados com exemplares contendo uma série de suas características (atributos) e uma categoria (rótulos) do exemplar. O objetivo é que o modelo aprenda a estabelecer correspondências entre características e rótulos
- **Aprendizado Não-Supervisionado (Unsupervised Learning):** Neste caso, algoritmos exploram conjuntos de dados sem rótulos para identificar padrões, estruturas ou agrupamentos intrínsecos.
- **Aprendizado por Reforço (Reinforcement Learning):** Este é um tipo de aprendizado em que um agente autônomo aprende a melhorar seu comportamento interagindo com seu ambiente e recebendo um feedback na forma de recompensas ou penalidades Sutton (1999). O agente deve aprender a escolher as ações que maximizam a recompensa ao longo do tempo.

O ML oferece vastas oportunidades de aplicação em diversas áreas do conhecimento. No campo das finanças, em particular, houve um aumento significativo na adoção de ML ao longo da última década, conforme atestam Warin & Stojkov (2021) que apresentam uma detalhada revisão bibliográfica, fornecendo uma ampla visão do estado da arte na área. Em outras áreas, como a saúde, técnicas de ML são empregadas na identificação de doenças cardiovasculares (Johan et al, 2024). No campo da educação, ML auxilia na previsão do abandono universitário, possibilitando intervenções direcionadas para aumentar a retenção de estudantes (Tito et al, 2023). E até mesmo para predição de tendências de furto (Ordóñez et al., 2020).

Assim, a motivação para estudar aplicações de ML na cobrança de dívidas seria para mostrar lacunas de pesquisa e as possibilidades de personalizar negociações, refinando táticas de comunicação. O ML pode ser aplicado em todas as etapas do ciclo de crédito e cobrança do cliente, abrangendo desde a prospecção até a recuperação de dívidas, mas os estudos começam a explorar essas técnicas, de forma ainda embrionária, conforme este artigo irá mostrar.

Este artigo procura trazer uma visão do estado da arte das pesquisas com aplicações de ML nas operações de cobranças de dívidas, e isto é feito, por meio de uma revisão sistemática da literatura (RSL), baseada na metodologia PICO (PAI et al., 2004). Busca-se compreender as motivações para a adoção de soluções baseadas em ML, o contexto no qual são utilizadas, os métodos de implementação, os algoritmos empregados, as métricas de avaliação de performance utilizadas, bem como as conclusões e avanços obtidos na interpretação dos resultados.

Além desta seção de introdução, tem-se no artigo, a seção 2, com a descrição da metodologia da pesquisa, e a seção 3 apresentando o desenvolvimento da RSL e os resultados obtidos. Na seção 4, tem-se uma discussão e análise dos resultados. E a seção 5, contém as considerações finais e recomendações do estudo.

2. Métodos e Materiais

O procedimento metodológico adotado para este estudo é o RSL Esta escolha se fundamenta em sua capacidade de empregar uma metodologia rigorosa e bem definida, que possibilita a identificação, análise e interpretação de pesquisas pertinentes à questão de pesquisa específica, como delineado por Kitchenham (2004). O MSL é uma ferramenta valiosa para investigar a literatura existente e aprofundar a compreensão das aplicações de técnicas de ML na cobrança de dívidas.

O protocolo metodológico seguido neste estudo está em conformidade com as diretrizes estabelecidas por kitchenham e Charters (2007), que delineiam um processo estruturado em três macro etapas essenciais: Planejamento, Condução do Mapeamento e Divulgação dos Resultados. Esse enfoque metodológico fornece um arcabouço sólido para conduzir uma análise sistemática e abrangente da literatura relevante a fim de responder às questões de pesquisa estabelecidas.

A seguir é apresentado o planejamento da RSL e depois a condução da busca nas bibliotecas digitais selecionadas.

2.1. Planejamento da RSL

O primeiro passo na elaboração desta RSL foi a definição do objetivo de pesquisa, que consiste em identificar na literatura científica estudos primários que proponham a **aplicação de técnicas de ML nas operações de cobrança de dívidas**. Além disso, busca-se compreender a forma como esses estudos foram conduzidos e os resultados obtidos com suas aplicações. Para atingir esse objetivo claramente definido, foram formuladas seis questões de pesquisa (QP) que direcionam a investigação:

QP1: Quando e onde os estudos foram publicados?

QP2: Quais são os principais objetivos das pesquisas desenvolvidas?

QP3: Em quais subcampos do ML as abordagens se inserem?

QP4: Quais *frameworks* metodológicos foram utilizados nos estudos?

QP5: Quais algoritmos são predominantemente utilizados nas pesquisas?

QP6: Quais métricas são empregadas para avaliação de desempenho das técnicas de ML?

A próxima etapa deste estudo abordará detalhadamente a estratégia e os métodos empregados na busca por trabalhos que possam responder a essas questões de pesquisa de maneira abrangente e rigorosa.

2.2. Condução da Busca por Obras na Literatura

Para a compilação dos estudos primários que compõem esta RSL, foram conduzidas pesquisas nas seguintes bibliotecas digitais nessa sequência de busca: Scopus, IEEE Xplore Digital Library e ACM Digital Library; adicionalmente, uma busca manual em português foi realizada na biblioteca digital da Sociedade Brasileira de Computação (SOL-SBC).

Neste estudo, a definição das palavras-chave seguiu a metodologia do protocolo PICO (PAI et al., 2004), uma abordagem estruturada que divide a questão de pesquisa em quatro elementos fundamentais:

- **P** (População): “*debt collection*”;
- **I** (Intervenção): “*machine learning*,” “*unsupervised learning*,” “*supervised learning*,” “*reinforcement learning*”;
- **C** (Comparação): Não se aplica (foco exclusivo em ML);
- **O** (Saída): descrição dos resultados dos estudos.

Para ajustar a estratégia de busca, foram realizados vários testes em cada um dos mecanismos de busca mencionados, com o objetivo de desenvolver uma *string* de busca que fornecesse resultados mais adequados, em consonância com as questões de pesquisa estabelecidas. A cada teste executado, uma análise minuciosa dos primeiros 10 resultados foi realizada, a fim de verificar se os títulos, resumos e palavras-chave estavam alinhados com o escopo da pesquisa.

A Tabela 1 apresenta as *strings* de busca ou equações de busca, utilizadas em cada uma das bibliotecas eletrônicas. Essas *strings* foram aplicadas nos campos de título, resumo e palavras-chave dos estudos, garantindo uma abordagem abrangente na identificação de trabalhos pertinentes para a revisão sistemática.

Biblioteca	String de Busca
SCOPUS	TITLE-ABS-KEY ((debt collection) AND (machine learning OR unsupervised learning OR supervised learning OR reinforcement learning))
IEEE Xplore e ACM	((debt collection) AND (machine learning OR unsupervised learning OR supervised learning OR reinforcement learning))
SOL	((“cobrança de dívidas”) AND (“aprendizado de máquina” OR “aprendizado não supervisionado” OR “aprendizado supervisionado” OR “aprendizado por reforço”))

Tabela 1 – *String* de busca por Biblioteca

3. Desenvolvimento da RSL e Resultados

Na fase de seleção dos estudos primários, foram estabelecidos inicialmente, critérios de **Inclusão** (I) e **Exclusão** (E) de estudos na seleção, de forma a selecionar aqueles de interesse na pesquisa. A Tabela 2 apresenta os critérios estipulados:

Crítérios	Descrição
I-1	Trabalho em Idioma inglês e português
I-2	Artigo disponível para <i>download</i>
I- 3	Trabalhos que abordarem técnicas de ML na cobrança de dívidas
I- 4	Trabalhos científicos completos publicados em veículos submetidos a revisão por pares
E-1	Estudo não disponível em inglês ou português

Critérios	Descrição
E-2	Artigo não disponível para download (acesso não gratuito), por impedir a leitura completa
E-3	Artigo duplicado em mais de um mecanismo de busca
E-4	Estudos que não abordarem técnicas de ML na cobrança de dívidas

Tabela 2 – Critérios de Inclusão e Exclusão de Estudos na Seleção

Após a aplicação dos critérios de inclusão e exclusão, foi definida nova fase, com dois critérios para avaliar a **Qualidade dos Estudos** primários que haviam sido selecionados na fase anterior:

- **Critério de Qualidade 1:** O estudo responde a alguma questão da pesquisa
Neste critério que trata das questões de pesquisa, todos os tipos de estudo foram considerados: teóricos, aplicações e estudos de caso.
- **Critério de Qualidade 2:** É artigo publicado em conferência ou periódicos?

Após a definição do protocolo de mapeamento, a estratégia de busca foi aplicada nas bibliotecas eletrônicas e bases de dados indexadas, SCOPUS, IEEE e ACM, em **20 de abril de 2023**. Além disso, uma busca foi realizada na base nacional SBC-SOL. Um total de 41 artigos foi o retorno obtido.

A Tabela 3 apresenta uma síntese da busca por biblioteca digital, e a tabela 4, apresenta a relação dos artigos finais selecionados para revisão. Alguns resultados eram duplicados em mais de um mecanismo de busca por isso a coluna “Publicações Duplicadas”, na tabela 3. Uma vez identificados esses artigos, o processo da RSL teve sequência em duas etapas de seleção.

Biblioteca	Publicações Localizadas	Publicações Duplicadas	Publicações Selecionadas
SCOPUS	19	1	13
IEEE	8	6	0
ACM	14	0	4
SOL	0	0	0
Total	41	7	17

Tabela 3 – Síntese da Busca de Estudos na Literatura

ID	Ano	Título	Autores
A1	2022	A machine-learning approach towards solving the invoice payment prediction problem	Schoonbee, L. and Moore, W.R. and van Vuuren, J.H.
A2	2022	Deep learning for modeling the collection rate for third-party buyers	Nazemi, A. and Rezazadeh, H. and Fabozzi, F.J. and Höchstötter, M.

ID	Ano	Título	Autores
A3	2021	Applying Machine Learning to Improve Collection and to Reduce Write-Offs in Utilities	Nascimento, B.S. and Maia, D. and Almada, L.
A4	2021	Predicting Accounts Receivable with Machine Learning: A Case in Malaysia	Ramanei, T.A.-P. and Abdullah, N.L. and Khim, P.T.
A5	2020	Detection of Taxpayers with High Probability of Non-payment: An Implementation of a Data Mining Framework	Placencia, J.O. and Hallo, M. and Lujan-Mora, S.
A6	2020	Using Behavioral Analytics to Predict Customer Invoice Payment	Bahrami, M. and Bozkaya, B. and Balcisoy, S.
A7	2020	Personalizing Debt Collections: Combining Reinforcement Learning and Field Experiment	Yang, Tracy; Lu, Tian; Li, Beibei; and Xianghua, Lu
A8	2015	A study on deliberate presumptions of customer payments with reminder in the absence of face-to-face contact transactions	Takahashi, M. and Azuma, H. and Tsuda, K.
A9	2014	A study on effect evaluation of payment method change in the mail-order industry	Takahashi, M. and Azuma, H. and Tsuda, K.
A10	2008	Using Predictive Analysis to Improve Invoice-to-Cash Collection	Zeng, Sai and Melville, Prem and Lang, Christian A. and Boier-Martin, Ioana and Murphy, Conrad
A11	2010	Optimizing Debt Collections Using Constrained Reinforcement Learning	Abe, Naoki and Melville, Prem and Pendus, Cezar and Reddy, Chandan K. and Jensen, David L. and Thomas, Vince P. and Bennett, James J. and Anderson, Gary F. and Cooley, Brent R. and Kowalczyk, Melissa and Domick, Mark and Gardinier, Timothy

Tabela 4 – Estudos Primários Seleccionados

Na primeira etapa da RSL, os critérios de inclusão e exclusão foram aplicados por meio da leitura dos títulos, análise dos resumos e palavras-chave, e nessa etapa 24 artigos foram excluídos, sendo 7 por serem publicações duplicadas, 13 por não abordarem técnicas de ML na cobrança de dívidas e 4 por não estarem disponíveis para *download*, restando, assim, 17 artigos, e que, por sua vez, geraram 11 artigos finais (tabela 4), seleccionados na fase seguinte, de avaliação da Qualidade dos Estudos. Note-se que os 17 artigos seleccionados na primeira fase de Inclusão/Exclusão, já passaram por leitura completa.

Na segunda fase, correspondente à avaliação da qualidade dos estudos, os artigos deveriam cumprir aos critérios de qualidade definidos, e se um artigo atendesse aos critérios estipulados, era incluído na seleção final. Desta segunda fase, resultaram os 11 artigos finais da tabela 4.

Aqui é importante considerar que, conforme mostra a primeira coluna da tabela 3, 41 artigos representam todas as obras que foram encontradas sobre o tema em quatro das principais bibliotecas digitais existentes. E note-se que as *strings* de busca procuraram ser abrangentes para que tivessem o maior alcance possível. E dentro desse nível de

abrangência, a busca trouxe 41 *papers*, que representam, segundo a busca, todas as pesquisas relatadas na literatura, publicadas nessas bibliotecas. Assim, pode-se considerar que os resultados são representativos do que vem sendo estudado e pesquisado nesse campo do conhecimento, que aparentemente, pelos números obtidos, não é um tema que tem chamado a atenção dos pesquisadores, constituindo-se desta forma, em uma lacuna de pesquisa a ser explorada.

4. Discussão e Análise dos Resultados

Esta seção fornece uma visão mais crítica dos resultados obtidos a partir da condução da RSL, e destaca a variedade de abordagens e técnicas utilizadas nos estudos selecionados. Essa análise contribui para a compreensão do estado da arte no uso de ML nas operações de cobrança de dívidas e demonstra a diversidade de estratégias adotadas para abordar os desafios nesse campo de pesquisa. A discussão e análise dos resultados estão organizadas de acordo com as questões de pesquisa pré-definidas.

Inicialmente, é dada uma visão geral dos artigos selecionados na fase final (tabela 6) e na sequência são apresentadas as respostas às questões de pesquisa.

4.1. Visão Geral dos Estudos Primários Selecionados

Dentre os 11 artigos analisados, seis deles abordam o problema de previsão de pagamento de faturas, que é um desafio comum na fase inicial da cobrança. Os artigos A1 (Schoonbee et al., 2022), A3 (Nascimento et al., 2021), A4 (Ramanei et al., 2021), A5 (Placencia et al., 2020), A6 (Bahrami et al., 2020) e A10 (Zeng et al., 2008), abordam esse problema e propõem soluções baseadas em ML. Estes artigos fazem uso de algoritmos como *DT* – *Decision Tree*, *RF* – *Random Forest*, *LR* – *Logistic Regression*, dentre outros.

No artigo A1 (Schoonbee et al., 2022), os autores propuseram um sistema de suporte à decisão (*Decision Support System* - DSS) para prever o comportamento de pagamento do cliente em relação às faturas emitidas em uma empresa na África do Sul.

Foram testados 6 diferentes tipos de algoritmos e para avaliação de desempenho os autores optaram por utilizar a curva ROC (*Receiver Operating Characteristic*) que demonstra a eficiência de um modelo em distinguir entre duas classes possíveis. Neste caso, a métrica utilizada foi a área abaixo da curva ROC (*AUC* – *Area under the Curve*), que varia entre 0 e 1, e quanto mais próximo de 1 melhor o desempenho do modelo. Dentre os modelos testados, o RF apresentou o melhor resultado, com AUC acima de 79%.

Já no artigo A3, Nascimento et al. (2021) discutem a cobrança de dívidas no setor público no Brasil, propondo a implementação de um *framework*. O objetivo era criar modelos de pontuação de predição de inadimplência, pagamentos espontâneos, e pagamento por resposta a ações de cobrança. Dentre os algoritmos testados, os autores utilizaram uma abordagem de comitê de algoritmo, que visa melhorar o desempenho de classificação.

O estudo apresentou resultados satisfatório de acordo com os autores, com uma AUC de 92% e Precisão de 86,96% para propensão de pagamento nos próximos 30 dias (semelhante resultados para os próximos 60 e 90 dias).

No artigo A4, Ramanei et al. (2021), também discutem o problema de previsão de pagamento de faturas em uma empresa na Malásia. A metodologia utilizada fez uso do *framework* metodológico, CRISP-DM DM (*Cross-Industry Standard Process for Data Mining*), desenvolvido por Shearer (2000). e testou os algoritmos DT e RF. Utilizou o nível de acurácia dos resultados para avaliar a capacidade de acerto dos modelos. Os resultados de desempenho entre os modelos foram muito parecidos, e o autores optaram por selecionar o algoritmo DT, pois as regras da árvore de decisão (*decision tree*) são facilmente interpretadas em comparação com o RF.

Já no artigo A5, Placencia et al. (2020) propõem um *framework* também baseado no CRISP-DM com o objetivo de prever dívidas de contribuintes de uma empresa no Equador com alta probabilidade de inadimplência utilizando técnicas de deep learning (DL). A métrica utilizada para medir o desempenho do modelo, foi o índice de concordância. O modelo final apresentou desempenho de 90%.

Bahrami et al. (2020), artigo A6, tinham como objetivo entender o comportamento do cliente em relação aos pagamentos de faturas e propor uma abordagem analítica para aprender e prever o comportamento de pagamento utilizando técnicas não supervisionadas e supervisionadas de ML. No *framework* desenvolvido, os autores propuseram diferentes abordagens para prever inadimplência. Uma das abordagens por exemplo, utilizava de algoritmos não supervisionados (K-Means e DBSCAN - *Density-based Spatial Clustering of Applications with Noise*) para agrupamento de dados (*clustering*), criando grupos de clientes, para só depois ser feita a criação dos modelos de classificação de dados, para cada grupo utilizando três abordagens de ML supervisionado: LR, *Support Vector Machine* (SVM) e *One Rule* (OneR). Foram utilizadas as métricas de AUC e Precisão para avaliar a capacidade preditiva dos modelos. Os resultados da regressão logística forneceram até 97% de precisão com ou sem pré-agrupamento de clientes.

No artigo A10, Zeng et al. (2008) demonstraram como o aprendizado supervisionado pode ser usado para construir modelos para prever os resultados de pagamento de faturas recém-criadas em quatro empresas nos Estados-Unidos. O algoritmo DT, do tipo C4.5 apresentou o melhor desempenho de acordo com a métrica acurácia.

Os autores puderam demonstrar por meio de simulação, que criação de um modelo preditivo para estimar a probabilidade de atraso no pagamento da fatura baseada no modelo de ML contribui para reduzir a inadimplência.

Em relação aos estudos analisados com foco na personalização da cobrança utilizando técnicas de ML foram identificados três artigos: A7 (Yang et al. 2020), A8 (Takahashi et al. 2015) e A9 (Takahashi et al. 2014), tem-se que em Takahashi et al. (2015), artigo A8, os autores investigaram as características dos clientes que geravam efeitos de lembrete na indústria de pedidos por correio, com ênfase nos clientes devedores. Até então, as investigações se concentravam em dados como endereço de entrega, nome do destinatário e método de pagamento, e a previsão desse conhecimento dependia das experiências dos funcionários. Para preencher essa lacuna, os autores analisaram dados de transações em conjunto com informações de clientes inadimplentes de uma empresa de pedidos por correio no Japão, utilizando a técnica *Self Organizing Maps* (SOM), um tipo especial de RNA de aprendizado não supervisionado. Os resultados da análise

permitiram a identificação de potenciais transações fraudulentas e a classificação de clientes intencionais e descuidados por meio de ML.

Em outro estudo desses autores Takahashi et al. (2014), artigo A9, realizaram a classificação de clientes inadimplentes com base nos registros de transações de uma empresa de venda de cosméticos por correios. O foco estava na mudança do método de pagamento. A análise revelou que a frequência de inadimplência aumentava à medida que o intervalo entre os pedidos era reduzido, e dependendo do montante financeiro dos pedidos. Foi conduzida uma pesquisa intensiva para identificar os clientes inadimplentes usando novamente a técnica SOM. Os resultados demonstraram que os clientes inadimplentes podiam ser detectados por meio da identificação de parâmetros específicos.

Yang et al. 2020, no artigo A7, desenvolveram um estudo no contexto de cobrança de dívidas de empréstimos, onde os cobradores geralmente fazem uso de ações baseadas em informações privadas e seguem uma estratégia de cobrança sequencial estrita. O estudo aplicou o aprendizado por reforço para otimizar a estratégia de cobrança. Um experimento de campo ajudou a validar e quantificar o valor econômico do algoritmo de otimização em um contexto do mundo real.

4.2. Respostas às Questões de Pesquisa

As QPs são respondidas nesta subseção na mesma sequência em que foram propostas.

QP1: Quando e onde os estudos foram publicados?

A partir da análise dos 11 estudos primários, observa-se que o primeiro estudo foi publicado em 2008. No entanto, o ano de 2020 se destaca, com três publicações realizadas. A Figura 1 apresenta a distribuição dos estudos ao longo dos anos.

Na Figura 2, é possível verificar a distribuição dos estudos por país de origem dos autores. Os Estados Unidos se destacam, com quatro estudos publicados, seguidos pelo Japão, com dois estudos. Os demais países apresentam apenas um estudo publicado. Notavelmente, o Brasil contribui com apenas um estudo, indicando que a pesquisa sobre o uso de ML na cobrança de dívidas ainda é incipiente no cenário brasileiro, especialmente considerando bases de dados em língua portuguesa.




Figura 1 – Estudos primários por ano de publicação



Figura 2 – Estudos primários por país de publicação

QP2: Quais são os objetivos primordiais das pesquisas desenvolvidas?

Conforme salientado na seção anterior, seis artigos abordaram o problema de previsão de pagamento de faturas, propondo soluções baseadas em ML. São os artigos: A1 (Schoonbee et al., 2022), A3 (Nascimento et al., 2021), A4 (Ramanei et al., 2021), A5 (Placencia et al., 2020), A6 (Bahrami et al., 2020) e A10 (Zeng et al., 2008). E sobre a personalização da cobrança utilizando técnicas de ML foram identificados três artigos: A7 (Yang et al. 2020), A8 (Takahashi et al. 2015) e A9 (Takahashi et al. 2014).

A tabela 5 revela esse quadro, em que a previsão de inadimplência é o objetivo central na aplicação de ML na cobrança de dívidas, abordado em 6 dos 11 artigos selecionados. Em seguida, soluções para personalização da cobrança são abordadas em 3 dos 11 artigos. Aplicações para previsão de recuperação de dívidas e otimização das ações de cobrança são temas de 1 estudo cada.

Aplicações	Número de Artigos
Previsão de inadimplência	6
Personalização das ações de cobrança	3
Previsão de recuperação de dívidas	1
Otimização de ações cobrança	1
Total	11

Tabela 5 – Objetivos das Aplicações de ML em Cobrança

QP3: Em que subcampos do ML as abordagens se inserem?

Os trabalhos analisados abrangem uma variedade de subcampos do ML, no entanto, o aprendizado supervisionado é o subcampo mais comumente aplicado, sendo utilizado em 7 dos 11 artigos selecionados (tabela 6).

Campos do ML	Número de Artigos
Aprendizado Supervisionado	7
Aprendizado Não Supervisionado	2
Aprendizado por Reforço	2
Total	11

Tabela 6 – Campos de ML dos estudos

QP4: Quais *frameworks* metodológicos foram utilizados nos estudos?

Nos estudos selecionados, a metodologia CRISP-DM (*Cross-Industry Standard Process for Data Mining*) foi utilizada em 3 dos 11 artigos utilizados (A1, A4 e A5). O CRISP-DM é um modelo de processo para análise e modelagem de dados, desenvolvido por Shearer (2000). Essa metodologia possui seis etapas: compreensão do negócio, entendimento e preparação dos dados, modelagem, avaliação e implantação.

A abordagem da CRISP-DM é iterativa e cíclica, o que significa que as etapas não são estritamente lineares. Essa flexibilidade é uma das razões pelas quais a metodologia CRISP-DM é tão popular: ela se adapta bem a projetos de ciência de dados que frequentemente envolvem descobertas e mudanças ao longo do processo. Foram identificados 4 estudos (A3, A6, A9 e A10) onde os autores criaram *frameworks*, propondo etapas de pré-processamento, criação e seleção de atributos, e avaliação dos modelos. Os demais artigos não abordaram de *frameworks* metodológicos.

QP5: Quais algoritmos são predominantemente utilizados nas pesquisas?

Os algoritmos explorados em cada artigo são apresentados na tabela 7.

ID	Ano	Algoritmos Utilizados
A1	2022	RF, DT, KNN - K-Nearest Neighbor, LR, NB, ANN
A2	2022	SVR – Support Vector Regression, DNN - Deep Neural Network ou DL - Deep Learning; Boosting com GBT – Gradient Boosted Trees, LR - Linear Regression, RT – Regression Tree
A3	2021	RF, XGBoost - Xtreme Gradient Boosting, LightGBM - Light Gradient Boosting Machine, CatBoost - Category Boosting, ET - Extremely Randomized Trees ou Extra Trees; LR; NB; ANN-MLP – Multilayer Perceptron, DL ou Deep MLP
A4	2021	DT e RF
A5	2020	DL
A6	2020	LR, SVM, OneR, K-means e DBSCAN

ID	Ano	Algoritmos Utilizados
A7	2020	CMDP - Constrained Markov Decision Process com Reinforcement Learning (RL)
A8	2015	ANN (arquitetura SOM)
A9	2014	ANN (arquitetura SOM)
A10	2008	DT, GBT, LR e NB
A11	2010	CMDP com Reinforcement Learning (RL)

Tabela 7 – Algoritmos Explorados nos Estudos Primários Seleccionados

E na Figura 4 tem-se os 19 algoritmos utilizados nas aplicações de ML. Destacam-se *Decision Tree* (DT) e *Logistic Regression* (LR), utilizados em 4 estudos cada. Em seguida, *Random Forest* (RF), *Naive Bayes* (NB), *Artificial Neural Network* (ANN) e *Deep Learning* (DL) empregados em 3 artigos, respectivamente.




Figura 4 – Tipos de Algoritmos utilizados nos estudos analisados

QP6: Quais métricas são empregadas na avaliação de desempenho das técnicas de AM?

Foram identificadas 9 métricas diferentes, com destaque para a Área sob a Curva ROC (*Area Under the Curve - AUC*) e a Acurácia (*Accuracy*), que são amplamente utilizadas em tarefas de classificação em métodos supervisionados. A AUC mede a capacidade de discriminação do modelo, sendo uma métrica que avalia a capacidade do modelo de distinguir entre classes. Quanto maior a AUC, melhor a capacidade de classificação do modelo. A Acurácia, por sua vez, mede a fração de instâncias corretamente classificadas dentre o total de instâncias recuperadas, sendo uma métrica fundamental para medir o desempenho do modelo.

A Figura 5 apresenta as métricas de avaliação de desempenho dos modelos utilizados nos estudos.




Figura 5 – Métricas de avaliação identificadas nos trabalhos

5. Considerações Finais e Recomendações

Este estudo contribuiu para uma maior compreensão do estado atual das aplicações de ML voltadas para as operações de cobranças de dívidas. Tendo-se identificado inicialmente 41 artigos associados ao tema, o número se consolidou em 11 artigos, após os filtros aplicados na RSL. Dentre as características identificadas, a predição de inadimplência foi preponderante, tendo estado presente em seis dos onze artigos analisados (54,5%). A personalização das ações de cobrança foi o segundo objetivo mais buscado (27,2%). E foram encontrados ainda, artigos que buscavam a otimização dos recursos das operações de cobranças de dívidas. Verifica-se assim, que a ênfase maior dos artigos se volta para a tentativa de modelagem do comportamento da inadimplência, o que certamente, pode ser um fator importante de apoio a decisões financeiras das empresas. Adicionalmente, foi possível identificar os algoritmos mais prevalentes nos estudos selecionados, notadamente, DT e LR.

Neste estudo, também foi possível identificar as métricas de avaliação de performance mais comuns, como: a área abaixo da curva ROC (AUC) e a Acurácia destacando-se nas tarefas de classificação de ML, enquanto a métrica Erro Quadrático Médio (MSE) figurou em dois artigos que lidavam com tarefas de regressão.

Em resumo, pelos resultados deste estudo é possível se verificar que as técnicas de ML têm o potencial de redefinir o cenário de operações de cobranças de dívidas podendo ser aplicado em todo o processo de cobrança de dívidas. Apesar dos desafios inerentes à implementação e interpretação desses modelos, os métodos de ML têm potencial de gerar resultados tão bons ou melhores que os métodos estatísticos tradicionais em determinadas aplicações, como na previsão do comportamento de clientes inadimplentes.

Além disso, tanto na condução da RSL quanto na análise dos estudos selecionados, verificou-se que existem questões de pesquisa ainda por responder, abrindo espaço para oportunidades de pesquisa futura, gerando aplicações práticas concretas. Dentre essas possibilidades de aplicações práticas, observa-se a subutilização de técnicas avançadas de Machine Learning (ML) na personalização da comunicação com devedores, aprimoramento de ofertas de desconto e identificação de horários ótimos de contato, particularmente no contexto brasileiro visando aumentar a eficiência dos processos de recuperação de dívidas.

Referências

- Abe, N., Melville, P., Pendus, C., Reddy, C. K., Jensen, D. L., Thomas, V. P., Bennett, J. J., Anderson, G. F., Cooley, B. R., Kowalczyk, M., Domick, M., & Gardinier, T. (2010). Optimizing debt collections using constrained reinforcement learning. *ACM Digital Library*. <https://doi.org/10.1145/1835804.1835817>
- Bahrami, M., Bozkaya, B., & Balcisoy, S. (2020). Using Behavioral Analytics to Predict Customer Invoice Payment. *Big Data*, 8(1), 25–37. <https://doi.org/10.1089/big.2018.0116>
- Brasil, (2023a). Portaria Normativa MF N° 634, DE 27 DE JUNHO DE 2023. Estabelece requisitos, condições e procedimentos para adesão ao Programa Emergencial de Renegociação de Dívidas de Pessoas Físicas Inadimplentes - Desenrola Brasil, criado pela Medida Provisória n° 1.176, de 5 de junho de 2023, e para a operacionalização do Programa. *Diário Oficial da União. Ministério da Fazenda/Gabinete do Ministro. Brasília. Publicada em 28/06/2023, Edição 121, Seção 1, p. 43. Disponível em: <https://www.in.gov.br/en/web/dou/-/portaria-normativa-mf-n-634-de-27-de-junho-de-2023-492539907>. Acesso em: 02/10/2023*
- Brasil (2023b). Portaria Normativa MF N° 733, DE 13 DE JULHO DE 2023. Dispõe sobre a habilitação de agentes financeiros no Programa Emergencial de Renegociação de Dívidas de Pessoas Físicas Inadimplentes - Desenrola Brasil, criado pela Medida Provisória n° 1.176, de 5 de junho de 2023, e sobre o enquadramento no Desenrola Brasil - Faixa 2. *Diário Oficial da União, Ministério da Fazenda/Gabinete do Ministro. Brasília. Publicada em 14/07/2023, Edição 133, Seção 1, p.18. Disponível em: <https://www.in.gov.br/en/web/dou/-/portaria-normativa-mf-n-733-de-13-de-julho-de-2023-496366355>. Acesso em: 02/10/2023*
- Dunn, P. K., & Smyth, G. K. (2018). Generalized Linear Models With Examples in R. In: *Springer texts in statistics*. <https://doi.org/10.1007/978-1-4419-0118-7>
- Hosmer, D. W., & Lemeshow, S. (2000). *Applied logistic regression (2nd ed.)*. John Wiley & Sons.
- IEEE. (2023). IEEE Xplore Digital Library. Disponível em <https://ieeexplore-ieee-org.ez347.periodicos.capes.gov.br/Xplore/guesthome.jsp>. Acesso em 20 de abril de 2023.
- Kitchenham, B. (2004). Procedures for performing systematic reviews. In: *Joint Technical Report, Software Engineering Group, Department of Computer Science, Keele University, United Kingdom, and Empirical Software Engineering, National ICT Australia Ltd, Australia*.
- Kitchenham, B., & Charters, S. (2007). Guidelines for performing systematic literature reviews in software engineering (Technical Report EBSE 2007-001). In: *Keele University and Durham University Joint Report*.
- Nascimento, B. S., Maia, D., & Almada, L. (2021). Applying Machine Learning to Improve Collection and to Reduce Write-Offs in Utilities. <https://doi.org/10.1109/aibt53261.2021.00017>

- Maimon, O., & Lior, R. (2014). *Data mining with decision trees: theory and applications* (2nd Ed.). World Scientific. Disponível em: https://doc.lagout.org/Others/Data%20Mining/Data%20Mining%20with%20Decision%20Trees_%20Theory%20and%20Applications%20%5bRokach%20%26%20Maimon%202008-04-01%5d.pdf
- Nazemi, A., Rezazadeh, H., Fabozzi, F. J., & Höchstötter, M. (2022). Deep learning for modeling the collection rate for third-party buyers. *International Journal of Forecasting*, 38(1), 240–252. <https://doi.org/10.1016/j.ijforecast.2021.03.013>
- Ordóñez, H., Cobos, C. & Bucheli, V. (2020). Modelo de machine learning para la predicción de las tendencias de hurto en Colombia. *RISTI - Revista Ibérica de Sistemas e Tecnologias de Informação*, (E29), 494-506.
- Pai, M., McCulloch, M., Gorman, J. D., Pai, N., Enanoria, W., Kennedy, G., Tharyan, P., & Colford Jr., J. M. (2004). *Clinical research methods - Systematic reviews and meta-analyses: An illustrated, step-by-step guide*. The National Medical Journal of India, 17(2), 86-94.
- Placencia, J. O., Hallo, M., & Lujan-Mora, S. (2020). Detection of Taxpayers with High Probability of Non-payment: An Implementation of a Data Mining Framework. <https://doi.org/10.23919/cisti49556.2020.9140837>
- Ramanei, T. A. P., Abdullah, N. L., & Khim, P. T. (2021). Predicting Accounts Receivable with Machine Learning: A Case in Malaysia. <https://doi.org/10.1109/icit52682.2021.9491773>
- Rocha, L. (2012). Framework for a global quality evaluation of a website. *Online Information Review*, 36(3), 374–382. <https://doi.org/10.1108/14684521211241404>
- Russell, S. J., & Norvig, P. (2022). *Inteligência Artificial - Uma Abordagem Moderna* (4ª Ed.). GEN LTC.
- Samuel, A. (1959) Some Studies in Machine Learning Using the Game of Checkers. *IBM Journal* 3(3),210–229.
- Schoonbee, L., Moore, W., & Van Vuuren, J. (2022). A Machine-Learning Approach Towards Solving The Invoice Payment Prediction Problem. *South African Journal of Industrial Engineering*, 33(4), 2726. <https://doi.org/10.7166/33-4-2726>
- Schwab, K. (2018). *A Quarta Revolução Industrial: tradução por Daniel Moreira Miranda*. Edipro SCOPUS. Acessado em: 20/04/2023.
- Sehn, C. F., & Carlini Junior, R. J. (2007). Inadimplência no Sistema Financeiro de Habitação: Um estudo junto à Caixa Econômica Federal (Caixa). *RAM - Revista de Administração Mackenzie*, 8(2), 59-84.
- SERASA. (2023). Mapa da inadimplência e negociação de dívidas no Brasil. Disponível em: <https://www.serasa.com.br/limpa-nome-online/blog/mapa-da-inadimplencia-e-renogociacao-de-dividas-no-brasil/>. Acesso em: 1 de maio de 2023.
- Shearer, C. (2000) The CRISP-DM Model: The New Blueprint for Data Mining. *Journal of Data Warehousing*, 5,13-22.

- Sociedade Brasileira de Computação (2023). SOL-SBC – SBC Open Lib. Disponível em: <https://sol.sbc.org.br/index.php/indice>. Acesso em: 20/04/2023
- Sutton, R.S. (1999). Reinforcement Learning. In: The MIT Encyclopedia of the Cognitive Sciences. MIT Press.
- Takahashi, M., Azuma, H., & Tsuda, K. (2014). A Study on Effect Evaluation of Payment Method Change in the Mail-order Industry. *Procedia Computer Science*, 35,871–878. <https://doi.org/10.1016/j.procs.2014.08.254>
- Takahashi, M., Azuma, H., & Tsuda, K. (2015). A Study on Deliberate Presumptions of Customer Payments with Reminder in the Absence of Face-to-face Contact Transactions. *Procedia Computer Science*, 60,968–975. <https://doi.org/10.1016/j.procs.2015.08.136>
- Tambellini, E. (2021), O Mercado de Cobrança e Recuperação de Crédito: ontem, hoje e amanhã. *Estação das Letras e Cores*.
- Tito, A., Orlando, B., & Pérez Vera, Y. (2023). Análisis comparativo de técnicas de machine learning para la predicción de casos de deserción universitaria. *RISTI - Revista Ibérica de Sistemas e Tecnologias de Informação*, (E51), 84-98. <https://doi.org/10.17013/risti.51.84-98>
- Warin, T., & Stojkov, A. (2021). Machine learning in finance: A metadata-based systematic review of the literature. *Journal of Risk and Financial Management*, 14(7), 302. <https://doi.org/10.3390/jrfm14070302>
- Wirth, R., Hipp, J. (2000). CRISP-DM: Towards a Standard Process Model for Data Mining. In: *Proceedings of the 4th International Conference on the Practical Applications of Knowledge Discovery and Data Mining*. Manchester, 11-13 April, 29-40.
- Yang, C., Lu, T., Li, B., & Lu, X. (2021). Personalizing debt collections: Combining reinforcement learning and field experiment. In: *ICIS 2020 Proceedings Article 2350 (International Conference on Information Systems, ICIS)*. Association for Information Systems. https://aisel.aisnet.org/icis2020/hci_artintel/hci_artintel/18/
- Yohannes, Y., & Hoddinott, J. (1999). Classification and regression trees: An introduction (Tech report). International Food Policy Research Institute. Disponível em: http://pdf.usaid.gov/pdf_docs/Pnach725.pdf
- Zeng, S., Melville, P., Lang, C. A., Boier-Martin, I., & Murphy, C. (2008). Using predictive analysis to improve invoice-to-cash collection. <https://doi.org/10.1145/1401890.1402014>

Aumento da maturidade de equipes SCRUM de desenvolvimento de software

Klauren Godoi Araújo Camargo¹, Napoleão Verardi Galegale¹

klaurengodoi@gmail.com; nvg@galegale.com.br

¹ CEETEPS - Centro Estadual de Educação Tecnológica Paula Souza, Rua dos Bandeirantes, 169 – Bom Retiro, CEP: 01124-010, São Paulo – SP, Brasil

DOI: [10.17013/risti.54.22-38](https://doi.org/10.17013/risti.54.22-38)

Resumo: A adoção de métodos ágeis no desenvolvimento de software vem aumentando a cada ano. Muito tem sido investido na preparação e capacitação de equipes neste sentido. O presente estudo desenvolve um roadmap para apoiar equipes scrum na evolução em níveis de maturidade ágil como instrumento complementar a um diagnóstico de níveis de maturidade desenvolvido e utilizado por uma instituição financeira brasileira de grande porte. Objetiva avaliá-lo quanto à usabilidade, factibilidade e utilidade por meio de demonstração em equipes e com grupo focal de especialistas em agilidade. Utilizou método de pesquisa Design Science Research Methodology (DSRM) e métodos complementares: survey, pesquisa bibliográfica, estudos de campo e entrevistas semiestruturadas para desenvolvimento e avaliação. O roadmap foi considerado pelas equipes participantes da demonstração e especialistas como de fácil usabilidade, factível e útil como apoio para adoção de práticas ágeis que contribuem para elevação de maturidade ágil para as equipes scrum da instituição financeira.

Palavras-chave: Roadmap; práticas ágeis; scrum; maturidade ágil; transformação digital.

Increasing the Scrum teams' maturity in software development

Abstract: Adoption of agile methods in software development has been increasing each year. Much has been invested in the preparation and training of teams in this regard. This study develops a roadmap to support scrum teams in evolving through levels of agile maturity as a complementary instrument to a diagnosis of maturity levels developed and used by a large Brazilian financial institution. It aims to evaluate it in terms of usability, feasibility and utility through demonstration with teams and a focus group of experts in agility. The research utilized Design Science Research Methodology (DSRM) and complementary methods: survey, literature research, field studies, and semi-structured interviews for development and evaluation. The roadmap was considered by the participating teams of the demonstration and experts as easy to use, feasible, and useful as support for the adoption of agile practices that contribute to the elevation of scrum teams' agile maturity of the financial institution.

Keywords: Roadmap; agile practices; scrum; agile maturity; digital transformation.

1. Introdução

No contexto do uso de tecnologia nas organizações, a adoção de metodologias ágeis para o desenvolvimento de software tem se tornado cada vez mais importante no mercado. Empresas buscam entregar *software* de forma contínua, colaborar com os clientes e gerar valor antecipado. As inovações, tais como o uso intensivo de *machine learning* em substituição de técnicas tradicionais de processamento da informação (Martins et al., 2022, 2023), são, não raras vezes, o motor para levar as organizações ao sucesso e para as manter na vanguarda perante os seus concorrentes. (Carvalho, Abreu & Rocha, 2018)

Nesse contexto, a empresa selecionada para este estudo é uma empresa brasileira de grande porte atuante na área financeira, com uma área de Tecnologia da Informação premiada e destacada, com robusta política de segurança da informação (Galeale et al., 2017). Para avaliar a maturidade das equipes *Scrum* da empresa na adoção de conceitos e práticas ágeis, foi customizado um modelo de maturidade denominado Níveis de Maturidade Ágil Institucional (NMAI), juntamente com um questionário chamado “Diagnóstico de *Scrum Teams*” (DTS).

No entanto, os resultados do diagnóstico revelaram que a maturidade das equipes *Scrum* era baixa, com a maioria nos níveis 1 e 2 de maturidade. Diante disso, o presente estudo propõe um artefato chamado *Roadmap* de Práticas Ágeis para *Scrum Teams* (RPATS) como complemento aos documentos NMAI e DTS, visando orientar a evolução da maturidade ágil das equipes *Scrum*.

A questão de pesquisa norteadora deste estudo pode ser assim apresentada: Um *roadmap* de práticas ágeis ordenadas contribui para aumentar a maturidade ágil das equipes *Scrum* da instituição financeira?

O objetivo geral é elaborar e avaliar a utilização do artefato RPATS como instrumento complementar na evolução dos níveis de maturidade ágil. Os objetivos específicos incluem a elaboração do referencial teórico, a definição do *design* do RPATS, o desenvolvimento do artefato, a demonstração para equipes *Scrum* da instituição financeira, a avaliação da utilização do RPATS pelas equipes e especialistas em agilidade, a divulgação do RPATS para a Equipe de Transformação Ágil da empresa e em eventos científicos e profissionais.

O método de pesquisa adotado é o DSRM (*Design Science Research Methodology*), que inclui estudos de campo, *survey*, entrevistas semiestruturadas e grupo focal de especialistas em agilidade.

Este artigo está estruturado em cinco seções principais. A Introdução apresenta o tema, os objetivos da pesquisa e a sua relevância. O Referencial Teórico revisa a literatura existente sobre o assunto, fundamentando teoricamente a pesquisa e fornecendo as práticas que comporão o artefacto a ser produzido. A seção de Metodologia descreve os procedimentos adotados para a coleta e análise dos dados, o delineamento da pesquisa, os instrumentos utilizados e a amostra estudada. Em Resultados e Discussão, são apresentados os achados da pesquisa e por fim, a Conclusão sintetiza os principais pontos

abordados, refletindo sobre as contribuições do estudo, suas limitações e sugerindo direções para pesquisas futuras.

2. Referencial Teórico

Com o objetivo de contemplar diferentes aspectos das práticas ágeis, modelos de maturidade e a abordagem de *roadmap*, a busca por referencial teórico se deu por meio de consultas às bases *Web of Science*, *Scopus* e Periódicos Capes, utilizado o algoritmo “*maturity model*” AND “*agile methodology*” e, posteriormente, expandida com as bases, *IEEE Xplore*, *ProQuest*, *SAGE Journal*, *ScienceDirect*, *Scopus*, *Web of Science*, *Wiley Journals e Springer Link*. As strings de busca utilizadas foram “*Agile best practices*” OR “*Agile good practices*” AND “*Agile Maturity Model*” OR “*Scrum Maturity Model*”. Não houve limitação temporal.

Após a junção de todas as buscas, a exclusão de duplicidades e a leitura dos resumos, foram selecionados 72 artigos disponíveis para acesso. Identificou diversos estudos sobre maturidade ágil, com ênfase na proposição e avaliação de modelos para equipes e processos, comparação de modelos, identificação de diferenças e aplicação de metodologias ágeis para alcançar altos níveis de maturidade no CMMI - *Capability Maturity Model Integration*. No entanto, não foram encontrados artigos específicos sobre ordenação de práticas ágeis. Os estudos foram utilizados para levantamento de práticas que comporiam o artefato RPATS.

Um estudo realizado por Gren et al (2019) investigou a correlação entre práticas ágeis e a maturidade da equipe, destacando os aspectos humanos e comportamentais. Yin (2011) desenvolveu o *Scrum Maturity Model* (SMM) como resposta a falhas em projetos de *software* e desalinhamentos na aplicação do *framework Scrum* para avaliar se a introdução de um modelo de maturidade melhoraria a cooperação com o cliente. Ozcan-Top e Demirörs (2013) questionaram a eficácia dos modelos de maturidade ágil existentes em fornecer informações sobre a capacidade ágil de uma organização, identificando seus pontos fortes e fracos. Eles realizaram cinco estudos de caso, utilizando diferentes modelos de maturidade, incluindo o *Agile Maturity Model* (AMM) e o *Scrum Maturity Model* (SMM), com resultados obtidos insatisfatórios, evidenciando lacunas em todos os modelos em algum aspecto do processo, concluindo necessário aprimorar os modelos de maturidade em relação à orientação para adoção, melhoria e avaliação de processos ágeis. Costa et al (2017) avaliaram a maturidade de uma empresa utilizando o *Scrum Maturity Model*, com o objetivo de propor melhorias no desenvolvimento de software e maximizar a maturidade dos processos ágeis. Nenhum dos modelos encontrados atendeu à questão de pesquisa deste estudo.

2.1. Metodologias ágeis

Metodologias ágeis são definidas como uma combinação de princípios de desenvolvimento que defendem a satisfação do cliente e a entrega incremental de produtos de *software* por equipes pequenas e altamente motivadas, utilizando métodos informais e buscando simplicidade no desenvolvimento (Pressman, 2011).

O Manifesto Ágil, formalizado em 2001, define valores fundamentais para a adaptabilidade e agilidade, priorizando indivíduos e interações, *software* funcional, colaboração com o cliente e aceitação de mudanças nos requisitos (Beck et al., 2001).

Diversos métodos de trabalho surgiram para atender aos princípios ágeis. O *Scrum* é o mais utilizado globalmente. Trata-se de um *framework* simples e leve, concebido por Jeff Sutherland e equipe, que busca a entrega de valor frequente e a redução de riscos nos projetos de desenvolvimento de software (Pressman, 2011; Sabbagh, 2017). É baseado em pilares de transparência, inspeção e adaptação e possui eventos formais, como reuniões de planejamento, revisão e retrospectiva da *Sprint*. Também define papéis específicos, como *Product Owner*, equipe de Desenvolvimento e *Scrum Master*, além de artefatos, como o *Backlog* do Produto, *Backlog* da *Sprint* e Incremento (Schwaber & Sutherland, 2017).

2.1.1. Práticas ágeis

Embora o *Scrum* não defina muitas práticas ágeis, ele prevê acoplamento de práticas oriundas de outros métodos ágeis em sua estrutura, conforme reporta Sabbagh (2017).

Nas referências bibliográficas pode-se encontrar pesquisas sobre práticas relacionadas com proposição de modelos de maturidade, práticas isoladas e listas de práticas adotadas mundialmente, construídas anualmente por meio de *surveys* desenvolvidas para análise e reporte do panorama de agilidade.

A consolidação das práticas ágeis mencionadas nos estudos utilizados incluem: acesso ao cliente e colaboração com o cliente, adaptação e aceitação de mudanças, uso do *Canvas MVP*, formação de equipes auto-organizadas com características específicas, utilização de casos de teste, colaboração com o cliente *on-site*, comunicação efetiva, definição de critérios de aceitação, adoção da *Definition of Done* (Definição de Pronto), implementação de desenvolvimento iterativo com iterações curtas, aplicação do desenvolvimento orientado a testes (TDD), utilização de metodologias como *Design Thinking*, *Lean Inception*, *Design Sprint*, Jornada de usuário e *Personas*, promoção de colaboração entre equipe *Scrum*, busca de estabilidade na equipe, estimativa de pontos de história e esforço através de técnicas como *Planning Poker*, obtenção de *feedback* rápido e periódico, gestão de projeto abrangendo pessoas, requisitos, mudanças e liberação, gerenciamento de *backlog* por meio de fatiamento, descarte e priorização, acompanhamento do progresso por meio de gráficos *Burn-up* e *Burn-down*, criação de histórias de usuário e metáforas, identificação de riscos de forma colaborativa, entrega de incrementos de produto e entregas frequentes, realização de inspeções contínuas, integração contínua, realização de *Lean Inception*, priorização da comunicação face a face e acordos orais, manutenibilidade e manutenção do software, elaboração de mapa de competências, trabalho no mesmo ambiente físico, estabelecimento de metas de *sprint* e *releases*, utilização de métricas de produtos como OKR, KPIs, negócio e ROI, análise de métricas de processos como *Cycletime*, *Leadtime*, CFD, WIP e fila de espera, modelagem de Objeto de Domínio, acompanhamento do *Net Promoter Score*, adoção de padrões de codificação, refatoração e comentário, prática de programação pareada, realização de pesquisa pós-venda para experiência do usuário, coleta de pesquisa de satisfação, planejamento de entregas e liberação através de *Release Plan* e *Roadmap*

de Entregas, implementação de plano de ação para melhoria contínua, priorização de histórias e criação de Mapa de Histórias de Usuário, priorização de tarefas, gerenciamento do *Product Backlog* e seu refinamento, dedicação de um *Product Owner*, adoção da programação em par, utilização de prototipagem, utilização de quadro de tarefas como o *kanban* digital e físico, busca pela qualidade de *software* e excelência técnica, elaboração de relatórios de progresso, realização de retrospectiva e *sprint review*, realização de reuniões diárias (*stand-up meetings*) ou *daily meetings*, revisão e controle de mudanças, presença do *Scrum Master* como treinador e facilitador, busca por soluções simples, gestão do *Sprint Backlog*, realização do *Sprint Planning* ou reunião de planejamento de *Sprint*, realização do *Sprint Review* ou reunião de revisão da *Sprint*, utilização de técnicas de ajuste metodológico, realização de testes de aceitação do cliente, implementação de testes unitários e regressão automatizados, utilização de *time-boxed* (limitação de tempo) e acompanhamento da vazão de entrega, velocidade de entrega, visão de produto e visibilidade do projeto, além do controle do trabalho em progresso (WIP). Essas práticas contribuem para a adoção e implementação de abordagens ágeis em projetos e equipes de desenvolvimento segundo os pesquisadores Patel e Ramachandran (2009); Yin (2011); Yin et al (2011); Santos et al (2011); Pichler (2011); Talluri e Haddad (2014); Cruz (2015); Layton (2015); Pichler (2016); Torrecilla-Salinas et al (2016); Schwaber e Sutherland (2017); Sabbagh (2017); Caroli (2018); Küpper et al (2019); Silva et al (2015); Campanelli e Parreiras (2015); Hughes (2013); Campanelli e Parreiras (2018); Gren et al (2019); Wilson e Mooz (2003); Chagas et al (2014); Albino (2017); Knapp et al (2017); Teixeira (2015); Sabaggh (2017); Doerr (2018); Beck et al (2001); Koscianski e Soares (2007); Anderson (2011); Turetken et al (2016).

Tais práticas foram utilizadas para seleção e construção do *Roadmap* de Práticas Ágeis para *Scrum Teams*– RPATS, produto (artefato) deste estudo.

2.2. Modelos de maturidade de equipes de desenvolvimento de software

A utilização de diversos modelos ou padrões para a implementação de melhoria de processos implica esforço, tempo e custo, gerando complexidade por conterem estruturas específicas. (Mejia, Muñoz, & San Feliu, 2018)

Para projetos de desenvolvimento ágil, as premissas de ambiente, processos de desenvolvimento e organização são muito diferentes das condições de projetos tradicionais (Leppänen, 2013). A busca por aprimoramento contínuo na agilidade é semelhante ao objetivo dos modelos de maturidade de fornecer direcionamentos para a evolução dos processos ao longo do tempo (Henriques & Tanner, 2017). A maturidade ágil concentra-se na implementação de processos e práticas alinhados com a abordagem ágil (Schweigert et al., 2013). Não há consenso sobre um modelo descritivo amplamente aceito para a maturidade ágil embora diversos tenham sido propostos. (Patel & Ramachandran, 2009).

Para este trabalho, foram selecionados dois modelos direcionados para o uso do *framework Scrum*: o *Agile Maturity Model* (AMM) (Patel e Ramachandran, 2009) e o *Scrum Maturity Model* (SMM) (Yin et al., 2011), por estarem citados em diversos artigos lidos e considerando dois fatores críticos determinantes: foco no *framework Scrum* e necessidade de alinhamento com a realidade da empresa em estudo.

2.3. Roadmap

O *Roadmap* é conceituado como uma ferramenta que oferece direcionamento e estratégias de inovação para o futuro do produto, estimulando reflexões, definições de metas de evolução e planos de ação para alcançá-las (De Reuver et al, 2013; Wagenaar et al, 2018; Carlos et al, 2018). É uma ferramenta de simples apresentação, mas muito desafiadora de desenvolver, apresentando um escopo amplo e complexas interações conceituais e humanas sendo sua flexibilidade é uma vantagem, permitindo a inclusão de diversos assuntos em diferentes níveis de detalhe. (Phaal et al., 2004, Phaal e Muller, 2009)

O formato mais comum é uma estrutura gráfica de múltiplas camadas, representando um plano detalhado que orienta o progresso em direção a uma meta (De Reuver et al., 2013). Neste sentido, o produto gerado no presente estudo é um *Roadmap* de Práticas Ágeis que permite às equipes *Scrum* identificarem seu ponto de partida nos *steps*, traçar a meta de evolução na maturidade da adoção de conceitos ágeis, e percorrer o caminho orientados pelas práticas sugeridas.

3. Metodologia

A escolha do método é uma das decisões fundamentais na condução do processo de pesquisa e o pesquisador precisa estar seguro de que o produto gerado agregará valor. (Cauchick-Miguel, 2018).

A pesquisa adotou o método *Design Science Research Methodology* (DSRM), aliado aos métodos de pesquisa bibliográfica, questionários (*survey*), entrevistas e estudo de campo. Lacerda et al. (2013) destacam que a metodologia *Design Science Research* é adequada para pesquisas em Engenharia de Produção, pois permite o desenvolvimento de artefatos que solucionem problemas existentes. Essa abordagem busca criar, recombinar ou alterar produtos, processos, *softwares* ou métodos para melhorar as situações atuais. Hevner et al (2004) enfatizam que uma pesquisa baseada na *Design Science* deve resultar em um artefato relevante criado para resolver um problema importante e sem solução prévia. A abordagem qualitativa foi utilizada para ordenar práticas ágeis que elevam a maturidade das equipes.

O estudo de campo ocorreu em 2020 com uma empresa financeira brasileira de grande porte cuja área de Tecnologia da Informação e Comunicação conta com aproximadamente 4 mil colaboradores e passava por uma transformação digital com adoção de processos ágeis. À época, possuía 319 equipes utilizando o *framework Scrum*. A empresa foi selecionada por atender as características estudadas pela pesquisa e concordou em participar do estudo, em anonimato, pelo seu interesse em elevar a maturidade de suas equipes de TI em relação a adoção dos métodos ágeis.

A empresa cedeu os resultados do questionário Diagnóstico de *Scrum Teams* - DTS, aplicado em novembro de 2019 às suas equipes de *Scrum*, bem como o documento Níveis de Maturidade Ágil Institucional – NMAI, os quais serviram de insumo para esta pesquisa.

O protocolo de pesquisa seguiu o modelo proposto por Peffers et al. (2007), detalhando cada uma das atividades do DSRM. Essas atividades envolveram a identificação do problema e sua justificativa, definição dos objetivos da solução, criação do artefato, demonstração de seu uso para resolver o problema, avaliação da eficácia do artefato e comunicação dos resultados para pesquisadores e outros públicos relevantes. A Figura 1 apresenta graficamente, o protocolo da pesquisa que norteou o desenvolvimento do artefato.

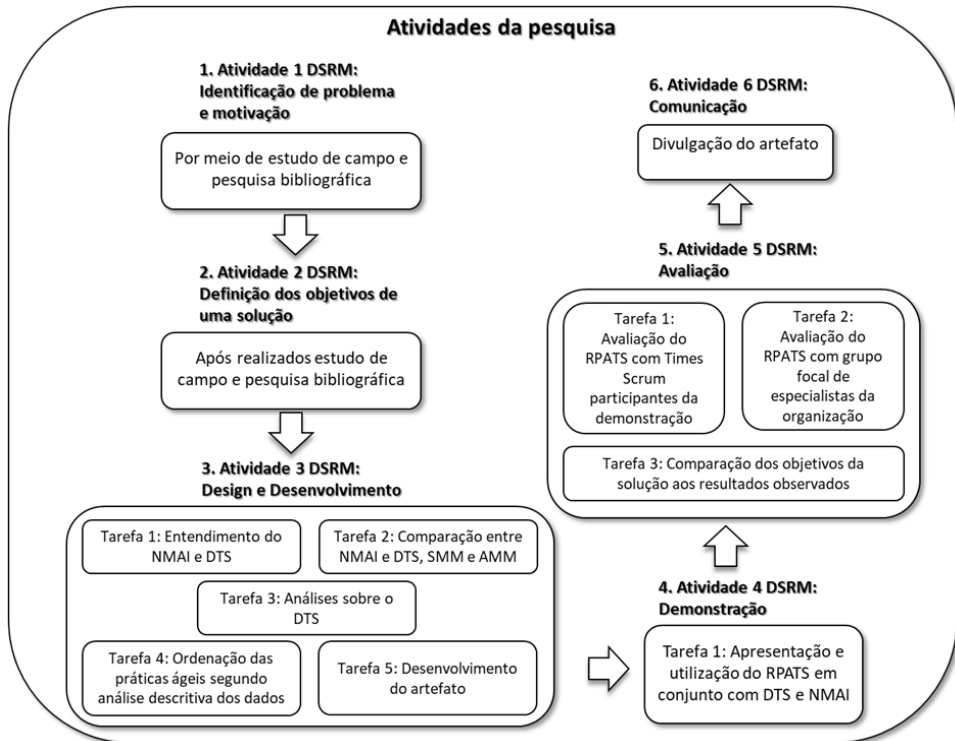


Figura 1 – Procedimentos da pesquisa

4. Resultados e discussão

Os resultados alcançados pela pesquisa foram agrupados de acordo com as atividades do DSRM. A primeira atividade: identificação do problema e motivação, consta na apresentação do estudo na Introdução.

4.1. Definição dos objetivos de uma solução

Conforme apresentado, a pesquisa tem por objetivo geral elaborar e avaliar a utilização do artefato RPATS como instrumento complementar na evolução dos níveis de maturidade ágil. Para fins de validação no estudo de campo, este objetivo pode ser

operacionalizado da seguinte forma: (i) fornecer o artefato; (ii) fornecer orientação aos *Scrum Masters* sobre utilização do artefato; (iii) elevar o *score* ou nível de maturidade das equipes *Scrum* participantes da atividade de demonstração do artefato; e (iv) avaliar factibilidade, utilidade e usabilidade do artefato.

4.2. Design e desenvolvimento do artefato Roadmap de Práticas Ágeis para Scrum Teams (RPATS)

A construção do RPATS seguiu os seguintes passos: (i) estudo do NMAI e do DTS existentes na empresa; (ii) Comparação entre NMAI e DTS com SMM e AMM; (iii) Análise da consistência do DTS da empresa por meio do cálculo do *alfa de Cronbach*, calculado por blocos de questões, cujos resultados variaram entre 0,63 e 0,88, indicando níveis aceitáveis de confiabilidade e consistência interna; (iv) ordenação das práticas ágeis segundo análise descritiva dos dados; e (v) desenvolvimento do artefato, apresentado na Tabela 1.

4.3. Demonstração

Cinco equipes de desenvolvimento de *software* utilizando *Scrum* foram indicados pela empresa para participar da atividade de demonstração do RPATS: uma equipe em formação e quatro já formados há mais tempo. O RPATS foi apresentado em uma reunião com os *Scrum Masters*, bem como a intenção de aplicá-lo em conjunto com o DTS e o NMAI durante duas *sprints*, com a finalidade de testar sua utilidade, factibilidade e usabilidade, bem como seu papel como orientação na melhoria da maturidade ágil das equipes.

4.4. Avaliação

Após cumprir a etapa de Demonstração, realizou-se a Etapa de Avaliação, cumprindo as 3 Tarefas detalhadas na figura 1. Para a Tarefa 1, foi encaminhado um questionário aos *Scrum Masters* das equipes participantes para coleta de dados sobre percepção das equipes em relação à utilização do RPATS, insumos para a realização da reunião de entrevista. A reunião com os 5 *Scrum Masters* para a entrevista teve duração aproximada de 2 horas. Os dados coletados pelos questionários e falas dos *Scrum Masters* durante a entrevista foram registrados pela pesquisadora e foram analisados em conjunto com os resultados das aplicações do DTS antes e depois das 2 *Sprints* que eles compartilharam com a pesquisadora. Em síntese, destacam-se os seguintes pontos apresentados pelas cinco equipes:

Equipe *Scrum A*: Composto por 8 desenvolvedores, 1 *Scrum Master* e 1 *Product Owner* e migrou gradualmente para uma metodologia ágil, adotando *Sprints* mensais e práticas do *Scrum*. A aplicação do “*kit*” foi útil para elevar a maturidade ágil. Embora não tenham alcançado um novo nível de maturidade, conseguiram aumentar seu *score* e aprofundar seu entendimento sobre conceitos ágeis.

Equipe *Scrum B*: Composto por 6 desenvolvedores, 1 *Scrum Master* e 1 *Product Owner*. A equipe considerou o RPATS útil para elevar sua maturidade ágil, pois ajudou a identificar práticas a serem revisadas ou adotadas e foi considerado fácil de ser seguido.

Roadmap de Práticas Ágeis para Scrum Teams		
Níveis de maturidade do NMAI e suas metas	Steps	Objetivo do Step
<p>1- Novato: Deseja praticar o ágil, mas não segue com frequência ou não compreende a correta utilização de ciclos curtos, entrega de valor, melhoria contínua e pilares do Scrum (transparência, inspeção e adaptação)</p> <p>Meta 1: Planejamento do projeto</p> <p>Meta 2: Aderência aos processos Scrum</p>	Step 1	<p>Formação do Equipe Scrum em torno da Visão do Produto buscando maior multifuncionalidade da equipe</p>
	Práticas recomendadas	<ul style="list-style-type: none"> - <i>Lean Inception</i>; - Visão do Produto; - <i>Canvas MVP</i> com previsão do resultado a ser atingido; - <i>Roadmap de Releases/Entregas</i>; - Lista inicial de funcionalidades do produto; - Pessoa treinadora do Scrum - <i>Scrum Master (SM)</i>; - Pessoa representante do cliente - <i>Product Owner (PO)</i>; - <i>Workshop Scrum</i> (ensinar sobre pilares, valores, papéis, ritos e artefatos); - Mapa de Competências; - Identificação de lacunas de conhecimento; - Treinamentos para suprir lacunas de conhecimento
	Step 2	<p>Geração de insumos sobre o produto para sprints de desenvolvimento</p>
	Práticas recomendadas	<ul style="list-style-type: none"> - Disponibilidade do PO para a equipe Dev (Desenvolvimento); - Escrita de itens de <i>Backlog</i> de Produto (metáforas ou Histórias de usuário); - Regras de negócio; - <i>Backlog</i> de Produto; - Refinamento de Itens de <i>Backlog</i> de Produto; - Definição de Pronto
	Step 3	<p><i>Sprints</i> de desenvolvimento: Ritos e artefatos</p>
	Práticas recomendadas	<ul style="list-style-type: none"> - <i>Sprint Planning</i> parte 1 (O que fazer); - <i>Sprint Planning</i> parte 2 (Como fazer); - Meta/Objetivo de <i>Sprint</i>; - <i>Backlog</i> de <i>Sprint</i>; - Estimativa de esforço (Horas por tarefa); - Estimativa de complexidade (Pontos de História de usuário); - Estimativa de capacidade de entrega (pode ser em pontos de História de usuário); - <i>Daily Meeting/</i> Reunião diária - Planejamento diário da equipe Dev (informal); - <i>Sprint Review</i>; - Inspeção do resultado da <i>Sprint</i>: PO; - <i>Sprint Retrospective</i>.

Roadmap de Práticas Ágeis para Scrum Teams		
Níveis de maturidade do NIMAI e suas metas	Steps	Objetivo do Step
		Práticas recomendadas
	<i>Step 4</i>	<p><i>Sprints</i> de desenvolvimento: Incremento de Produto</p> <ul style="list-style-type: none"> - Gerenciamento de <i>Backlog</i> de <i>Sprint</i> (Priorização, inclusão, exclusão de tarefas); - Facilitação pelo SM (Aplicação de técnicas, práticas e conceitos no dia a dia com a equipe); - Testes de <i>software</i>; - Manutenção de <i>software</i>; - Monitoramento de trabalho não planejado (<i>abend</i>, manutenção, correção); - Inspeção do Incremento de Produto: apresentação e <i>feedback</i> do PO e partes interessadas
	<i>Step 5</i>	<p>Trabalhar a evolução da equipe <i>Scrum</i> enquanto equipe</p> <ul style="list-style-type: none"> - Planejamento de ausências transparente e visível (Autogestão da equipe <i>Scrum</i>); - Uso do <i>Parking lot</i> nas <i>daily</i>s garantindo foco no planejamento diário; - Plano de ação para melhoria d equipe; - Participação da equipe <i>Scrum</i> em Comunidades de prática; - Encontros periódicos de <i>Scrum Masters</i> da empresa para troca de experiências
2- Aprenderiz: Começa a praticar o ágil e está aprendendo a compreender a correta utilização de ciclos curtos, entrega de valor, melhoria contínua e pilares do <i>Scrum</i> (transparência, inspeção e adaptação)	<i>Step 1</i>	<p>Aprimoramento do <i>Roadmap</i> de <i>Releases/Entregas</i></p> <ul style="list-style-type: none"> - <i>Design Thinking, Lean Inception, Design Sprint, Jornada de usuário, Personas</i>; - <i>Roadmap de Releases/Entregas</i> com declaração dos objetivos e benefícios das entregas; - Gerenciamento do <i>Roadmap de Releases/Entregas</i>; - <i>Canvas MVP</i> com detalhamento de escopo, esforço, custo, métricas de produto para o MVP; - Negociação prévia com áreas intervenientes; - ROI (Retorno sobre investimento)
Meta: Planejamento de projeto – entregas e itens de Backlog	<i>Step 2</i>	<p>Aprimoramento no Gerenciamento do <i>Backlog</i> de Produto</p> <ul style="list-style-type: none"> - Gerenciamento de <i>Backlog</i> de Produto (Escrita, Fatiamento, Descarte e Priorização de Histórias de usuário); - Refinamento de Itens de <i>Backlog</i> de Produto; - Mapa de Histórias de usuário; - Matriz de Priorização; - Histórias de usuário contendo as regras de negócio, critérios de aceite e cenários de testes; - <i>Sprint Planning 2</i> (Como fazer: detalhamento das tarefas, gerenciamento e priorização, além da estimativa)

Roadmap de Práticas Ágeis para Scrum Teams		
Níveis de maturidade do NIMAI e suas metas	Steps	Objetivo do Step
<p>3- Praticante: Prática agilidade e compreende a correta utilização de ciclos curtos, entrega de valor, melhoria contínua e pilares do Scrum (transparência, inspeção e adaptação)</p> <p>Meta: Gestão de Iterações (sprints) por métrica de processo</p>	Step 1	<p>Métricas de processo para entendimento da capacidade de entrega da equipe</p> <p>- <i>Throughput</i> (Quantidade de Histórias de usuário entregues); - Pontos de História de usuário planejados por <i>Sprint</i>; - Pontos de História de usuário entregues por <i>Sprint</i>; - Gráfico <i>Burn-up</i> da <i>Sprint</i>; - Quantidade de Histórias de melhoria/evolução entregues por <i>Sprint</i>; - Quantidade de Histórias de manutenção/correção de problemas entregues por <i>Sprint</i>; - Mapa de Histórias de melhoria/evolução <i>versus</i> Histórias de manutenção/correção de problemas</p>
	Step 2	<p>Métricas de processo para acompanhamento do ciclo de desenvolvimento do produto</p> <p>- <i>Cyclétime</i>; - <i>Leadtime</i>; - <i>Leadtime breakdown</i>; - CFD (<i>Cumulative Flow Diagram</i>)</p>
<p>4- Experiente: Prática agilidade e compreende a correta utilização de ciclos curtos, entrega de valor, melhoria contínua e pilares do Scrum (transparência, inspeção e adaptação), tirando proveito das boas práticas em prol da sua evolução</p> <p>Meta: Gestão de qualidade de Incremento de produto por métrica de produto</p>	Step 3	<p>Métricas de processo para trabalho a capacidade e sustentabilidade no fluxo de desenvolvimento</p> <p>- WIP (<i>Working in Progress</i>); - Fila de espera</p>
	Step 1	<p>Métricas de produto – acompanhamento de resultado de lançamento, resultado de negócio e satisfação do cliente</p> <p>- KPIs (<i>Key Performance Indicator</i>) de negócio; - OKR (<i>Objectives and Key Results</i>) de produto; - NPS (<i>Net Promoter Score</i>); - Pesquisa de Satisfação com usuário</p>

Roadmap de Práticas Ágeis para Scrum Teams			
Níveis de maturidade do NMAI e suas metas	Steps	Objetivo do Step	Práticas recomendadas
<p>5- Referência: Possui grande expertise em praticar o ágil, utilização de ciclos curtos, entrega de valor, melhoria contínua e pilares do <i>Scrum</i> (transparência, inspeção e adaptação) e pode ser considerado referência para demais equipes</p> <p>Meta: Gestão da Qualidade do produto</p>	<p>Step 1</p>	<p>Qualidade do Produto</p> <ul style="list-style-type: none"> - excelência técnica e Satisfação do cliente englobando pesquisa de usabilidade 	<ul style="list-style-type: none"> - Testes automatizados; - Testes de regressão; - Comentário de código; - Refatoração de código; - Pesquisas de pós-venda (UX)

Tabela 1 – Roadmap de práticas ágeis para Scrum Teams – RPATS

Equipe Scrum C: Composto atualmente por 5 desenvolvedores, 1 *Scrum Master* e 1 *Product Owner*. Equipe em formação e seguiu as práticas do Nível 1 do RPATS, alcançando o objetivo de formar a equipe em torno da Visão do Produto. A *Scrum Master* vê benefícios no direcionamento da equipe e considera o RPATS útil para facilitar seu trabalho e propor melhorias ao grupo.

Equipe Scrum D: Composto por desenvolvedores de alta, baixa plataforma e mobile, 1 *Scrum Master* e 1 *Product Owner* e já possuía familiaridade com o *Scrum*. Como resultado da última aplicação do DTS, a equipe identificou que estava no nível de maturidade 2 - Aprendiz. Após testar o RPATS e reaplicar o DTS elevou sua maturidade para o nível 3 - Praticante, aumentando seu *score* em 34 pontos. Considerou as práticas sugeridas no RPATS úteis e claras.

Equipe Scrum E: Composto por 6 desenvolvedores, 1 *Scrum Master* e 1 *Product Owner*. Adotaram o *Scrum* como forma de gerenciamento de projetos, no entanto, enfrentaram desafios devido às constantes trocas de *Product Owners*, A aplicação do RPATS foi considerada fácil e possibilitou à equipe seguir um processo claro para escolher e adotar práticas ágeis.

Como resultado da Tarefa 2, a avaliação do RPATS com grupo focal de especialistas da instituição financeira foi baseada nos critérios de factibilidade, utilidade e usabilidade do artefato RPATS em conjunto com DTS e NMAI. Foi realizada por três especialistas com vasta experiência e conhecimento em agilidade e *Scrum* da empresa, não inseridos no contexto da elaboração do DTS nem do NMAI, visando manter a imparcialidade. Foram realizadas iterações de avaliação, incluindo uma reunião em formato de *workshop* para discutir o RPATS e seus propósitos, seguida por um questionário. Os resultados mostraram que os especialistas concordaram que o RPATS é factível, de fácil uso e útil pois facilita a compreensão e adoção de práticas ágeis e contribui para a elevação da maturidade das equipes.

Para concluir a Tarefa 3 a avaliação foi realizada comparação da funcionalidade do artefato com os objetivos da solução, de acordo com Peffers et al (2007). O primeiro objetivo foi alcançado durante as etapas de *design* e desenvolvimento do RPATS, assim como na atividade de demonstração, onde o artefato foi disponibilizado às equipes *Scrum*. O segundo objetivo foi cumprido por meio da realização de reuniões com os *Scrum Masters* para explicar como utilizar o artefato. O terceiro objetivo foi alcançado com a elevação do *score* ou nível de maturidade das equipes participantes da demonstração, com resultados positivos e depoimentos favoráveis das equipes. O quarto objetivo, que envolveu a avaliação de factibilidade, utilidade e usabilidade do artefato, foi atingido segundo avaliação tanto pelas equipes quanto pelos especialistas em agilidade da instituição. Por fim, o objetivo principal de elaborar e avaliar o RPATS como instrumento complementar ao DTS e NMAI foi alcançado, com indicação de divulgação do artefato para as demais equipes *Scrum* da instituição financeira.

4.5. Comunicação

Os resultados da utilização do RPATS foram comunicados em reunião interna da empresa e o artefato RPATS foi disponibilizado a todas as equipes, acompanhado do

“Roteiro para aplicação do RPATS”, “Orientações e *links* para auxiliar na aplicação das práticas”.

Adicionalmente, este artigo foi elaborado para comunicar resultado do estudo e propiciar acesso aos profissionais que possam se beneficiar com a utilização do artefato.

5. Conclusão

O trabalho atingiu seu objetivo e demonstrou resultados positivos, tanto para a empresa participante do estudo de campo, como para a academia.

Para a empresa, o RPATS é um conjunto de práticas ágeis subdivididas em cinco níveis, alinhados aos níveis de maturidade do NMAI com orientações para a adoção de tais práticas pelas equipes *Scrum*, possibilitando às equipes alcançarem o próximo nível de maturidade.

O artefato foi avaliado quanto à utilidade, factibilidade e usabilidade com cinco equipes *Scrum* da empresa e grupo focal de especialistas em agilidade da empresa, tendo sido considerado útil, de fácil usabilidade e capaz de elevar a maturidade das equipes. No geral, o feedback foi favorável, destacando o valor do RPATS para os *Scrum Masters* na implementação de práticas e elevação da maturidade das equipes.

Entretanto, este estudo possui limitações em relação à aplicação do artefato em outros contextos e à consideração de aspectos comportamentais e de relacionamento interpessoal que também influenciam a maturidade ágil. Como trabalhos futuros, recomenda-se a generalização do RPATS para outros modelos de maturidade e outras empresas que tenham equipes *Scrum* em seu ambiente de desenvolvimento de *software*. Considerar ampliar o tempo de experimentação na etapa de Demonstração espaçando o tempo para permitir experimentação de mais práticas.

Referências

- Albino, R. D. (2017). *Métricas Ágeis: obtenha melhores resultados em sua equipe*. Casa do Código.
- Anderson, D. J. (2011). *Kanban: mudança evolucionária de sucesso para seu negócio de tecnologia*. Blue Hole Press.
- Beck, K., Beedle, M., van Bennekum, A., Cockburn, A., Cunningham, W., Fowler, M., & Kern, J. (2001). Manifesto para desenvolvimento ágil de software. Recuperado de <http://agilemanifesto.org/iso/ptbr/manifesto.html>
- Campanelli, A. S., & Parreiras, F. S. (2015). Agile methods tailoring: A systematic literature review. *Journal of Systems and Software*, 110, 85-100. <https://doi.org/10.1016/j.jss.2015.08.035>
- Campanelli, A. S., Camilo, R. D., & Parreiras, F. S. (2018). The impact of tailoring criteria on agile practices adoption: A survey with novice agile practitioners in Brazil. *Journal of Systems and Software*, 137,366-379. <https://doi.org/10.1016/j.jss.2017.12.012>

- Carlos, R., Amaral, D. C., & Caetano, M. (2018). Framework for continuous agile technology roadmap updating. *Innovation & Management Review*, 15(3),321-336. <https://doi.org/10.1108/INMR-05-2018-0030>
- Caroli, P. (2018). *Lean Inception: como alinhar pessoas e construir o produto certo* (1ª ed.). Editora Caroli.
- Carvalho, J. V., Abreu, A., & Rocha, Á. (2018). Informática Industrial. RISTI - *Revista Ibérica de Sistemas e Tecnologias de Informação*, (27). <https://doi.org/10.17013/risti.27.0>
- Cauchick-Miguel, P. A. (Coord.). (2018). *Metodologia de pesquisa em engenharia de produção e gestão de operações* (3ª ed.). Elsevier.
- Chagas, L. F., et al. (2014). Systematic literature review on the characteristics of agile project management in the context of maturity models. *In International Conference on Software Process Improvement and Capability Determination*. Springer, 177-189. https://doi.org/10.1007/978-3-319-13036-1_16
- Costa, R., Rodrigues, R., & Dutra, A. C. S. (2017). Application of scrum maturity model in soft design company. *In Brazilian Workshop on Agile Methods*. Springer, 39-49. https://doi.org/10.1007/978-3-319-55907-0_4
- Cruz, F. (2015). *Scrum e agile em projetos: guia completo*. Brasport.
- De Reuver, M., Bouwman, H., & Haaker, T. (2013). Business model roadmapping: A practical approach to come from an existing to a desired business model. *International Journal of Innovation Management*, 17(01), e1340006. <https://doi.org/10.1142/S1363919613400069>
- Doerr, J. (2019). *Avalie o que importa: como o Google, Bono Vox e a Fundação Gates sacudiram o mundo com os OKRs*. Alta Books.
- Galeale, N. V., Fontes, E.L.G. & Galeale, B. P. (2017). Uma contribuição para a segurança da informação: um estudo de casos múltiplos com organizações brasileiras. *Perspectivas em Ciência da Informação*, 22(3),75-97. <https://doi.org/10.22478/ufpb.1981-0695.2018v13n1.39334>
- Gren, L., Goldman, A., & Jacobsson, C. (2019). Agile ways of working: A team maturity perspective. *Journal of Software: Evolution and Process*, 32(6),e2244. <https://doi.org/10.1002/smr.2244>
- Henriques, V., & Tanner, M. (2017). A systematic literature review of agile and maturity model research. *Interdisciplinary Journal of Information, Knowledge, and Management*, 12,053-073.
- Hevner, A. R., March, S. T., Park, J., & Ram, S. (2004). Design science in information systems research. *MIS Quarterly*, 28(1),75-105. <https://doi.org/10.2307/25148625>
- Hughes, R. (2013). Starting and scaling agile data warehousing. *Agile Data Warehousing Project Management*, 303-344.

- Knapp, J., Zeratsky, J., & Kowitz, B. (2017). *Sprint: O método usado no Google para testar e aplicar novas ideias em apenas cinco dias* (1ª ed.). Intrínseca.
- Küpper, S., et al. (2019). How has SPI changed in times of agile development? Results from a multi-method study. *Journal of Software: Evolution and Process*, 31(11), e2182. <https://doi.org/10.1002/smr.2182>
- Lacerda, D. P., et al. (2013). Design science research: A research method for production engineering. *Gestão & Produção*, 20(4), 741-761.
- Layton, M. C. (2015). *Scrum for dummies*. Willey.
- Leppänen, M. (2013). A comparative analysis of agile maturity models. In *Information Systems Development*. Springer, 329-343. https://doi.org/10.1007/978-1-4614-4951-5_27
- Mejia, J., Muñoz, M., & San Feliu, T. (2018). Tendencias en Tecnologías de Información y Comunicación. *RISTI - Revista Ibérica de Sistemas e Tecnologias de Informação*, (26). <https://doi.org/10.4304/risti.35.0>
- Martins, E. & Galegale, N. V. (2022). Retail sales forecasting information systems: comparison between traditional methods and machine learning algorithms. In *Proceedings of the 2022 International Conference Information Systems (IADIS)*, 30-38. https://doi.org/10.33965/is2022_202201004
- Martins, E. & Galegale, N. V. (2023). Machine learning: A bibliometric analysis. *International Journal of Innovation*, 11(3), 1-37. <https://doi.org/10.5585/2023.24056>
- Ozcan-Top, O., & Demirörs, O. (2013). Assessment of agile maturity models: A multiple case study. In *International Conference on Software Process Improvement and Capability Determination*. Springer, 130-141. https://doi.org/10.1007/978-3-642-38833-0_12
- Patel, C., & Ramachandran, M. (2009). Agile Maturity Model (AMM): A software process improvement framework for agile software development practices. *International Journal of Software Engineering*, 2(1), 3-28.
- Peppers, K., et al. (2007). A design science research methodology for information systems research. *Journal of Management Information Systems*, 24(3), 45-77. <https://doi.org/10.2753/MIS0742-1222240302>
- Phaal, R., Farrukh, C. J. P., & Probert, D. R. (2004). Technology roadmapping: A planning framework for evolution and revolution. *Technological Forecasting and Social Change*, 71(1-2), 5-26. [https://doi.org/10.1016/S0040-1625\(03\)00072-6](https://doi.org/10.1016/S0040-1625(03)00072-6)
- Phaal, R., & Muller, G. (2009). An architectural framework for roadmapping: Towards visual strategy. *Technological Forecasting and Social Change*, 76(1), 39-49. <https://doi.org/10.1016/j.techfore.2008.03.018>
- Pichler, R. (2011). *Gestão de produtos com Scrum: Implementando métodos ágeis na criação e desenvolvimento de produtos*. Elsevier.

- Pichler, R. (2016). *Strategize: Product strategy and product roadmap practices for the digital age*. Pichler Consulting.
- Pressman, R. S. (2011). *Engenharia de software* (7ª ed.). Bookman.
- Sabbagh, R. (2017). *Gestão ágil para projetos de sucesso*. Casa do Código.
- Santos, R., et al. (2011). Agile technical management of industrial contracts: Scrum development of ground segment software at the European Space Agency. In *International Conference on Agile Software Development*. Springer, 290-305. https://doi.org/10.1007/978-3-642-20677-1_21
- Schwaber, K., & Sutherland, J. (2017). The scrum guide-the definitive guide to scrum: The rules of the game. Recuperado de <https://www.scrum.org>
- Schweigert, T., et al. (2013). Agile maturity model: A synopsis as a first step to synthesis. In *European Conference on Software Process Improvement*. Springer, 214-227. https://doi.org/10.1007/978-3-642-39179-8_19
- Silva, F. S., et al. (2015). A reference model for agile quality assurance: Combining agile methodologies and maturity models. In *9th Internacional Conference on the Quality of Information and Communications Technology*. IEEE, 139-144. <https://doi.org/10.1109/QUATIC.2014.25>
- Teixeira, F. (2015). Google Design Sprint: Como funciona e como aplicar no seu projeto. Recuperado de <https://brasil.uxdesign.cc/google-design-sprint-como-funciona-e-como-aplicar-no-seu-projeto-279107363659>
- Wagenaar, G., et al. (2018). Working software over comprehensive documentation: Rationales of agile teams for artefacts usage. *Journal of Software Engineering Research and Development*, 6(1), 1-23. <https://doi.org/10.1186/s40411-018-0051-7>
- Yin, A. P. G. (2011). Scrum maturity model (Dissertação de mestrado). Instituto Superior Técnico - Universidade Técnica de Lisboa.
- Yin, A., Figueiredo, S., & da Silva, M. M. (2011). Scrum maturity model: Validation for its organizations roadmap to develop software centered on the client role. In *The Sixth International Conference on Software Engineering Advances, ICSEA*, 20-29.

Inteligencia artificial en el estudio del uso de escaneo cerebral en la implementación en usuarios neurodivergentes

Mateo Dwyer¹

mateodwyer@gmail.com

¹ Universidad Autónoma de Querétaro, Mexico.

DOI: [10.17013/risti.54.39-51](https://doi.org/10.17013/risti.54.39-51)

Resumen: La salud mental en general es un tema que ha ganado mucha relevancia e importancia en los últimos años. Pero un elemento central de ésta es el tema de trastornos mentales, y el diagnóstico de ellos. Por mucho tiempo, el método estándar usado para este proceso ha sido lento y costoso. Sin embargo, con nuevas tecnologías como son la inteligencia artificial y el escaneo cerebral hay posibilidad de una detección más rápida, sencilla, y objetiva de estos trastornos, incluido a edades más tempranas. El objetivo de este estudio es verificar la eficacia del reconocimiento de patrones eléctricos cerebrales mediante la inteligencia artificial en el uso médico psicológico, utilizando opiniones profesionales para determinar su factibilidad. El análisis fue cuanti-cualitativo, y se encontró que estas herramientas probablemente serán indispensables para esta área en el futuro cercano, siempre y cuando se le de un enfoque particular a su desarrollo.

Palabras-clave: neurodivergente, diagnóstico, trastorno mental, escaneo cerebral, inteligencia artificial.

Artificial intelligence in the study of the use of brain scans in neurodivergent diagnosis

Abstract: Mental health in general is a subject that has become more and more relevant in the past years. But a central element to this subject is mental disorders, and their diagnosis. For a long time, the standard method used for this project has been lengthy and expensive. However, with new technologies such as artificial intelligence and brainwave scanning there is a chance for faster, simpler, and more objective detection of these disorders, including at ages too young for the current method. The objective of this study is to verify the efficiency of the recognition of brainwave patterns using artificial intelligence in the psychology-medicinal field, using professional opinions to determine its feasibility. The analysis was quantitative, and it was found that these tools will most likely be indispensable for this field in the near future, as long as they are given the proper development.

Keywords: neurodivergent, diagnosis, mental disorder, brain scans, artificial intelligence.

1. Introducción

La salud mental es un tema que ha ganado relevancia significativa en los últimos años. Con los efectos que la pandemia tuvo sobre el estado emocional de las personas, más y más personas e institutos se han dedicado a su estudio, y aun culturalmente han aumentado las discusiones y los cuidados personales que se toman las personas. Un elemento de este tema que se ha comenzado a estudiar con más frecuencia es el diagnóstico de trastornos mentales, ya que conocer cualquier problema existente es indispensable para poder tratarla.

Otro tema de interés reciente es la inteligencia artificial. Ha existido por mucho tiempo como concepto; sin embargo, ahora se está haciendo una realidad, con algoritmos y programas capaces de reconocer y replicar patrones de manera verbal y hasta artística. Con esta ayuda, una gran variedad de trabajos se pueden hacer de manera más eficiente y barata; uno de estos trabajos es, en teoría, el diagnóstico de trastornos.

Existen varios trabajos empíricos y experimentales realizando pruebas sobre este tema, los cuales se usarán como fundamento para la presente investigación.

2. Método

El objetivo de esta investigación documental de carácter cuantitativo y cualitativo fue identificar el alcance y la utilidad posible de los escaneos de patrones eléctricos cerebrales junto con la inteligencia artificial dentro del área de psicología médica, con énfasis en el proceso de diagnóstico inicial de neurodivergencia. Para cumplir lo anterior, se realizó una revisión sistemática de la literatura especializada al respecto. La revisión sistemática se realizó en cuatro fases:

2.1. Búsqueda de documentos pertinentes a la investigación

Se realizó una búsqueda sistemática de artículos de investigación en las bases de datos científicas Mendeley, SciELO, Dialnet y Google Académico. Para ser más fiel a las fuentes originales, en lugar de 'Mendeley' se registraron bajo las revistas originales de las cuales se compilaron. La obtención de documentos se realizó comenzando el 22 de agosto de 2023 y el análisis se realizó desde esa fecha hasta el 8 de octubre de 2023. Se admitieron textos publicados en cualquier idioma desde el 2019 hasta el 2023.

2.2. Definición de criterios de inclusión y exclusión de los documentos obtenidos

La búsqueda en las bases de datos científicas se realizó usando palabras clave. Las palabras usadas fueron 'neurodivergent', 'diagnosis', 'mental disorder', 'brain scans', y 'artificial intelligence', normalmente encadenadas. En español fueron 'neurodivergente', 'diagnóstico', 'trastorno mental', 'escaneo cerebral' e 'inteligencia artificial'. En la base de datos la búsqueda se desarrolló en el título, el resumen, las palabras clave y el documento extenso. Se obtuvo la siguiente cantidad de documentos: SciELO 3; Google Académico, 18; Diagnostics, 3; Computers and Biology in Medicine, 3; fuentes mixtas

(muchas recolectadas en Mendeley), 93. En total, se obtuvieron 120 documentos. Posteriormente, se identificaron los documentos duplicados y se eliminaron 4. Además, se realizó una revisión de la pertinencia de los documentos obtenidos y se eliminaron los que no eran útiles para el análisis de esta investigación. Por la facilidad y disponibilidad de información, se eliminaron todas aquellas fuentes sin DOI o ISSN, y se eliminaron aquellas fuentes con poca o relativamente menos relevancia con el tema central de estudio, y las que se enfocan en trastornos mentales más probables a desarrollarse debido a factores externos. Finalmente, se admitieron 64 documentos para el análisis.

2.3. Análisis y categorización

Se realizó un análisis cuantitativo para saber en qué años se publicaron más documentos sobre los trastornos mentales y su diagnóstico, en qué países y con qué enfoque (ver Tabla 1). El análisis cuantitativo se condujo respondiendo preguntas de investigación.

Temas de análisis	Preguntas de investigación
<i>Año de publicación</i>	¿Cuántas publicaciones sobre este tema se realizaron cada año desde el 2019?
<i>País de origen</i>	¿Qué países han demostrado un enfoque mayor en este tema?
<i>Trastorno enfoque del artículo</i>	De los artículos que mencionan enfoque en algún trastorno en particular, ¿cuál resultó el más común?

Tabla 1 – Preguntas de investigación de carácter cuantitativo

Asimismo, se realizaron categorías de análisis para identificar las formas de diagnóstico actuales, las ‘pros’ y ‘contras’ como tal del uso de escaneo cerebral en dicho proceso, y las recomendaciones existentes sobre la introducción de inteligencia artificial en el área de psicología. Este análisis fue cualitativo y también se condujo con preguntas de investigación (ver Tabla 2).

Temas de análisis	Preguntas de investigación
<i>Propuestas actuales</i>	¿Cómo se propone que se realice el proceso de diagnóstico con el uso de herramientas de escaneo e inteligencia artificial?
<i>Modificaciones al área de estudio</i>	¿Cuáles cambios son necesarios para llegar a la integración e implementación de estos instrumentos?
<i>Beneficios</i>	¿Cuáles serían los beneficios de la introducción de estas tecnologías en este campo y para este fin?

Tabla 2 – Preguntas de investigación de carácter cualitativo

2.4. Discusión

La discusión se presenta, propiamente, en la sección Conclusiones de este texto.

3. Resultados

3.1. Resultados del análisis cuantitativo

El análisis cuantitativo trajo consigo una gran cantidad de resultados interesantes. Sin embargo, primero se dará una breve descripción de los artículos conseguidos, y los temas que tratan.

Los artículos que fueron considerados para la realización de esta investigación fueron todos aquellos que trataron el diagnóstico de trastornos mentales, con un énfasis por los que mencionaron la utilización de inteligencia artificial y/o los escaneos cerebrales (EEG o fMRI). Como ya fue mencionado en la fase dos de la metodología, se admitieron un total de 64 artículos a consideración.

El primer dato a considerar de entre todos los artículos recopilados es la fecha de publicación. Se debe destacar que dentro de la presente investigación se excluyeron documentos con fecha de publicación antes del año 2019, en su mayoría gracias a que el tema objeto de estudio ha surgido recientemente.

Los resultados, visibles en la Figura 1, resultaron interesantes; desde el 2019 hasta el 2022 se nota una tendencia de crecimiento demasiado alta, antes de caer de nuevo en el 2023. Sin embargo, esto se puede deber simplemente al hecho de que el 2023 sigue en curso.




Figura 1 – Número de artículos recopilados por año

Entre el 2019 y el 2020 no se vio mucho crecimiento. Sin embargo, en el 2021 incrementó de seis artículos a 12, antes de llegar a 28 en 2022. Hasta la fecha de septiembre de 2023 se encontraron 13 artículos relacionados.

El siguiente dato que se revisó fue el país de publicación. Este dato es interesante gracias a lo que puede demostrar sobre interés cultural sobre estos temas, además del posible costo de los estudios. Los resultados se muestran en la figura 2.




Figura 2 – Número de artículos recopilados por país

Existió, dentro de los resultados, un país en particular que demostró el mayor interés en temas de trastornos mentales y su diagnóstico asistido. Reino Unido aportó 18 de los totales 64 artículos, seguido por los Estados Unidos con 11, y Suiza y Países Bajos con 6. Polonia, India, y China aportaron más de un artículo cada uno, mientras que los demás fueron publicados en áreas sin especificación o países europeos, en su mayoría. Pocas fueron provenientes de países americanos o asiáticos. Esto se puede deber a interés a nivel cultural, o también al hecho de que los países más involucrados son países desarrollados, y tienen más recursos para invertir en este campo.

Por último, entre aquellos artículos que mostraron un enfoque en algún trastorno mental en particular, se analizó la frecuencia de aquellos mencionados por nombre, como se muestra en Figura 3. Nota: las siglas y los nombres de cada trastorno se muestran en inglés; en español, de orden descendente son Trastorno de Espectro Autista (TEA, ASD por siglas en inglés), Trastorno de Déficit de Atención e Hiperactividad (TDAH, ADHD por siglas en inglés), y dislexia.

Como se puede observar, tanto el TEA como el TDAH se han estudiado de manera profunda. Esto se podrá deber, en su mayoría, a lo común que es encontrar ambos trastornos, y la creciente demanda para poder diagnosticarlos de manera segura, rápida, y eficaz. Con menos prioridad se encuentra la dislexia, también un trastorno común pero uno más fácil de diagnosticar por sus síntomas sencillos de describir y reconocer.

Es interesante observar la prioridad que tiene cada uno de los trastornos mencionados, ya que se puede asociar además al impacto que tiene cada uno a la sociedad y a los individuos afectados. Sin embargo, también es importante notar que las tecnologías y técnicas desarrolladas utilizando a los escaneos cerebrales y la inteligencia artificial como herramientas no necesariamente deben de llevar un enfoque particular, sino que se pueden desarrollar con el fin de ser adaptados a distintas áreas y tipos de diagnóstico.




Figura 3 – Número de artículos recopilados que mostraron enfoque particular en un trastorno mental

3.2. Resultados del análisis cualitativo

La primera pregunta que se planteó fue la siguiente: ¿Cómo se propone que se realice el proceso de diagnóstico con el uso de herramientas de escaneo e inteligencia artificial?

Para empezar, se hizo consideración en cuanto al método actual de diagnóstico. Existen variaciones en cuanto al trastorno particular; sin embargo, tanto para TEA y TDAH el procedimiento estándar es mediante entrevistas y análisis de conducta por un individuo altamente capacitado. Este procedimiento es lento, ya que se requiere de tiempo para cada paciente individual, además de costoso, haciéndolo inaccesible para muchas personas. Adicionalmente, no es posible realizar el diagnóstico en un paciente de menos de dos años como mínimo. (Helmy E, Elnakib A, Elnakieb Y et al, 2023)

En cuanto al sistema propuesto, es un tema demasiado complicado, pero en términos generales, el escaneo cerebral forma una especie de mapa tridimensional del cerebro y su actividad. Con este formato es difícil para la inteligencia artificial detectar patrones, por lo que se debe de transformar en un plano bidimensional; ya de esta manera, el software podrá detectar y reconocer distintos tipos de patrones los cuales indican distintos tipos de trastornos. (Sadiq M, Akbari H, Siuly S et al, 2021)

Siguiendo esto, se preguntó ¿Cuáles cambios son necesarios para llegar a la integración e implementación de estos instrumentos? En los artículos consultados se dieron varias propuestas, las principales de las cuales se muestran en la Tabla 3.

Como se puede observar, una de las propuestas principales para llegar a un futuro donde estas tecnologías se puedan utilizar de manera confiable y segura depende de su continuo desarrollo con un enfoque específico a esta área. Para esto, se requiere de personas que empujen este desarrollo e impulsen los cambios necesarios.

Cambios propuestos	
1.-	Determinación de los patrones a reconocer para cada trastorno a diagnosticar
2.-	Capacitación de personal para la utilización de estas tecnologías
3.-	Pruebas exhaustivas sobre su funcionamiento y capacidades
4.-	Empuje por parte de profesionales hacia el desarrollo de las tecnologías relevantes

Tabla 3 – Cambios necesarios para la aplicación de las nuevas tecnologías en el área de psicología

Las demás propuestas son importantes tanto antes como después de que las tecnologías lleguen al nivel apropiado de avance; sin suficientes pruebas y datos no importa lo eficiente que sea la tecnología, ya que no sabrá qué se tiene que detectar.

Para empezar, se hizo consideración en cuanto al método actual de diagnóstico. Existen variaciones en cuanto al trastorno particular; sin embargo, tanto para TEA y TDAH el procedimiento estándar es mediante entrevistas y análisis de conducta por un individuo altamente capacitado. Este procedimiento es lento, ya que se requiere de tiempo para cada paciente individual, además de costoso, haciéndolo inaccesible para muchas personas. Adicionalmente, no es posible realizar el diagnóstico en un paciente de menos de dos años como mínimo. (Helmy E, Elnakib A, Elnakieb Y et al, 2023)

La última pregunta realizada fue sobre los beneficios; ¿qué beneficios tendrían estas tecnologías? Para responder esta pregunta es importante analizar las desventajas del modelo actual. Como ya se mencionó brevemente, el presente modelo obliga cierta lentitud en el proceso, en gran parte debido a la carencia de personal capacitado.

Un beneficio significativo de la utilización de estas herramientas sería el incremento masivo en eficiencia, tanto en cuanto al tiempo de diagnóstico como a su objetividad. A continuación se desglosan las razones de cada uno.

Para empezar, el tiempo requerido para diagnosticar con seguridad algún trastorno bajaría dramáticamente. Las mismas actitudes y conductas inconscientes del paciente pueden ser monitoreadas y analizadas por una máquina de deep learning al mismo tiempo que se haga la prueba tradicional, aportando resultados simultáneos y rápidos. Por supuesto, este uso en particular viene con riesgos, en especial cuando se trata de confiabilidad de resultados. Un estudio reciente demostró que, en la actualidad, la inteligencia artificial cuenta con un grado medio de confiabilidad. En trastornos comunes, como dependencia al alcohol, TDAH, o TEPT, alcanzó predecir correctamente en alrededor de 75% de los casos. Sin embargo, en otros casos se inclinaba más hacia el 60%. (Heinz M, Bhattacharya S, Trudeau B et al, 2023)

Es decir, usado como herramienta dentro del proceso de diagnóstico podrá aportar un nivel de confiabilidad adicional, pero no puede reemplazar los demás métodos. Aún así, cuando se considera que los niveles de diagnóstico incorrecto (ya sea falta de diagnóstico o diagnóstico de un trastorno distinto al actual) pueden oscilar entre 70 y 98%, se puede ver que el aporte dado por este nuevo método es significativo.

Finalmente, en cuanto a objetividad, es uno de los temas muy relevantes en esta área. Como ya se mencionó la probabilidad de que alguien sea diagnosticada de forma incorrecta es alta, y esto se le puede atribuir, en parte, al carácter subjetivo de algunos de los procesos de diagnóstico. Claramente se tiene como meta la objetividad al momento de diagnosticar, pero el simple hecho de que exista un elemento humano puede causar variaciones que no se tendrían que ver en otro caso. El tener evidencias concretas del funcionamiento distinto del cerebro de un paciente podrá ayudar a un sinnúmero de personas quienes, bajo otro especialista, tendrían la capacidad de ser diagnosticadas incorrectamente.

4. Conclusiones

El diagnóstico de trastornos mentales es un elemento extremadamente importante para la salud mental de un individuo. El conocimiento de lo que lo afecta, junto con el acceso a recursos que ayudan a aliviar a los síntomas, son integrales a su desarrollo, y el desarrollo de tecnologías que logran eficientizar este proceso es siempre importante.

La inteligencia artificial como tecnología ha tenido un progreso explosivo en los últimos años, y se han encontrado aplicaciones para ella en casi todo campo profesional. En el caso de la psicología y la medicina la inteligencia artificial tiene usos extensos, en especial utilizando su reconocimiento de patrones para analizar conductas y síntomas y llegar a conclusiones rápidas y objetivas. No solamente es viable su aplicación en esta área, sino que ya se está introduciendo.

Mientras tanto, los escaneos cerebrales también se siguen desarrollando. La información que produce este método es complicada, y, mientras que es posible su interpretación por medio de personas, es mejor en muchos casos transformarla en un plano bidimensional para permitir que algún software de inteligencia artificial analice los patrones encontrados.

En fin, ambas tecnologías deben de ser utilizadas en conjunto para producir resultados. Sin embargo, estos resultados requieren de apoyo, manejo e interpretación humana. Estas tecnologías son solamente herramientas; no pueden ser sustituciones.

Referencias

- Abd-Alrazaq, A., Alhuwail, D., Schneider, J., et al. (2022). The performance of artificial intelligence-driven technologies in diagnosing mental disorders: an umbrella review. *Nature*. <https://doi.org/10.1038/s41746-022-00631-8>
- Ahmad, N., Rehman, M., El Hassan, H., et al. (2022). An Efficient Machine Learning-Based Feature Optimization Model for the Detection of Dyslexia. *Computational Intelligence and Neuroscience*. <https://doi.org/10.1155/2022/8491753>
- Albajara Sáenz, A., Villemonteix, T., Massat, I. (2019). Structural and functional neuroimaging in attention-deficit/hyperactivity disorder. *Developmental Medicine and Child Neurology*. <https://doi.org/10.1111/dmcn.14050>

- Anchana, V., Biju, K. (2023). Comparative Study of Detection of ADHD using EEG Signals. 2023 International Conference on Control, Communication and Computing (ICCC). 10.1109/ICCC57789.2023.10165395
- Arji, G., Erfannia, L., Aliarezaei, A., et al. (2023). A systematic literature review and analysis of deep learning algorithms in mental disorders. *Informatics in Medicine Unlocked*. <https://doi.org/10.1016/j.imu.2023.101284>
- Bakhtyari, M., Mirzaei, S. (2022). ADHD detection using dynamic connectivity patterns of EEG data and ConvLSTM with attention framework. *Biomedical Signal Processing and Control*. <https://doi.org/10.1016/j.bspc.2022.103708>
- Barua, P., Dogan, S., Baygin, M., et al. (2022). TMP19: A Novel Ternary Motif Pattern-Based ADHD Detection Model Using EEG Signals. *Diagnostics*. 10.3390/diagnostics12102544
- Barua, P., Vicnesh, J., Gururajan, R., et al. (2022) Artificial Intelligence Enabled Personalised Assistive Tools to Enhance Education of Children with Neurodevelopmental Disorders—A Review. *International Journal of Environmental Research and Public Health*. <https://doi.org/10.3390/ijerph19031192>
- Bayram, M., Özer, Í., Termurtas, F. (2021). Deep Learning Methods for Autism Spectrum Disorder Diagnosis Based on fMRI Images. *Sakarya University Journal of Computer and Information Sciences*. <https://doi.org/10.35377/saucis.04.01.879735>
- Bouallegue, G., Djemal, R., Alshbeili, S., et al. (2020). A Dynamic Filtering DF-RNN Deep-Learning-Based Approach for EEG-Based Neurological Disorders Diagnosis. <https://doi.org/10.1109/ACCESS.2020.3037995>
- Boughattas, N., Jabnoun, H. (2022). Autism Spectrum Disorder (ASD) Detection Using Machine Learning Algorithms. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*. https://doi.org/10.1007/978-3-031-09593-1_18
- Byrne, D., Gorman, K., Twomey, E., et al. (2021). Yield of diagnosis in MRI brain imaging in children with autism spectrum disorder. *Developmental Medicine and Child Neurology*. <https://doi.org/10.1007/s00431-023-05011-2>
- Chen, Z., Kulkarni, P., Glatzer-Levy, I., et al. (2022). Modern views of machine learning for precision psychiatry. *Patterns*. <https://doi.org/10.1016/j.patter.2022.100602>
- Farooq, M., Tehseen, R., Sabir, M., et al. (2023). Detection of autism spectrum disorder (ASD) in children and adults using machine learning. *Scientific Reports*. <https://doi.org/10.1038/s41598-023-35910-1>
- Farooqui, Q., Rahman, M. (2022). Autism Spectrum Disorder (ASD) Diagnosis and Reinforcement by Machine Learning and Neural Networks. 2022 Second International Conference on Artificial Intelligence and Smart Energy (ICAIS). <https://doi.org/10.1109/ICAIS53314.2022.9742946>
- Feng, X., Hu, M., Guo, W. (2022). Application of artificial intelligence in mental health and mental illnesses. 2022 3rd International Symposium on Artificial Intelligence for Medicine Sciences. <https://doi.org/10.1145/3570773.3570834>

- Firouzabadi, F., Ramenzanpour, S., Firouzabadi, M., et al. (2022). Neuroimaging in Attention-Deficit/Hyperactivity Disorder: Recent Advances. *American Journal of Roentgenology*. <https://doi.org/10.2214/AJR.21.26316>
- Gupte, N., Patel, M., Pen, T., et al. (2023). Early detection of ADHD and Dyslexia from EEG Signals. *2023 IEEE 8th International Conference for Convergence in Technology, I2CT 2023*. <https://doi.org/10.1109/I2CT57861.2023.10126272>
- Heinz, M., Bhattacharya, S., Trudeau, B., et al. (2023). Testing domain knowledge and risk of bias of a large-scale general artificial intelligence model in mental health. *Digital Health*. <https://doi.org/10.1177/20552076231170499>
- Helmy, E., Elnakib, A., Elnakieb, Y., et al. (2023). Role of Artificial Intelligence for Autism Diagnosis Using DTI and fMRI: A Survey. *Biomedicines*. <https://doi.org/10.3390/biomedicines11071858>
- Hilal, A., Issaoui, I., Obayya, M., et al. (2022). Modeling of explainable artificial intelligence for biomedical mental disorder diagnosis. *Computers, Materials & Continua*. <https://doi.org/10.32604/cmc.2022.022663>
- Huse, S., Acharaya, S., Shukla, S., et al. (2022). Computer-Aided Detection and Diagnosis of Neurological Disorder. *Cureus*. <https://doi.org/10.7759/cureus.28032>
- Jain, P., Quadri, S. (2021). Emerging Role of Intelligent Techniques for Effective Detection and Prediction of Mental Disorders. *Lecture Notes on Data Engineering and Communications Technologies*. https://doi.org/10.1007/978-981-15-9509-7_16
- Jatain, A., Vashisht, P. (2023). A novel approach for diagnosing neuro-developmental disorders using artificial intelligence. *Dialnet*. <https://doi.org/10.4114/intartif.vol26iss71pp13-24>
- Joy, R., George, S., Rajan, A., et al. (2022). Detection and Classification of ADHD from EEG Signals Using Tunable Q-Factor Wavelet Transform. *Journal of Sensors*. <https://doi.org/10.1155/2022/3590973>
- Kaisar, S. (2020). Developmental dyslexia detection using machine learning techniques: A survey. *ICT Express*. <https://doi.org/10.1016/j.icte.2020.05.006>
- Khare, S., Gaikwad, N., Bajaj, V. (2022) VHERS: A Novel Variational Mode Decomposition and Hilbert Transform-Based EEG Rhythm Separation for Automatic ADHD Detection. *IEEE Transactions on Instrumentation and Measurement*. <https://doi.org/10.1109/TIM.2022.3204076>
- Khodatars, M., Shoebi, A., Sadeghi, D., et al. (2021). Neuroimaging database and machine learning-based analysis for neurological disorders. *Computers in Biology and Medicine*. <https://doi.org/10.1016/j.compbiomed.2021.104949>
- Kister, K., Laskowski, J., Makarewicz, A., et al. (2023). Application of artificial intelligence tools in diagnosis and treatment of mental disorders. *Current Problems of Psychiatry*. <https://doi.org/10.12923/2353-8627/2023-0001>

- Kresnia, G., Parikesit, A. (2022). Use of Artificial Intelligence in the Diagnostics of Autism Spectrum Disorder. *Cermin Dunia Kedokteran*. <https://doi.org/10.55175/cdk.v49i6.246>
- Kusano, K., Tashiro, T., Matsubara, T., et al. (2019). Deep Generative State-Space Modeling of fMRI Images for Psychiatric Disorder Diagnosis. *Proceedings of the International Joint Conference on Neural Networks*. [https://doi.org/10.1109/IJCNN.\(2019\).8852448](https://doi.org/10.1109/IJCNN.(2019).8852448)
- Loh, H., Ooi, C., Barua, P., et al. (2022). Automated detection of ADHD: Current trends and future perspective. *Computers in Biology and Medicine*. <https://doi.org/10.1016/j.combiomed.2022.105525>
- Maniruzzman, M., Hasan, M., Asai, N., et al. (2023). Optimal Channels and Features Selection Based ADHD Detection From EEG Signal Using Statistical and Machine Learning Techniques. *IEEE Access*. <https://doi.org/10.1109/ACCESS.2023.3264266>
- Maniruzzman, M., Shin, J., Hasan, M., et al. (2022). Efficient Feature Selection and Machine Learning Based ADHD Detection Using EEG Signal. *Computers, Materials and Continua*. <https://doi.org/10.32604/cmc.2022.028339>
- Martinhago, F., Lavagnino, N., Folguera, G., et al. (2019). Factores de riesgo y bases genéticas: el caso del trastorno por déficit de atención e hiperactividad. <https://doi.org/10.18294/sc.2019.1952>
- Murugappan, M., Yuvaraj, R. (2022). Biomedical Signals Based Computer-Aided Diagnosis for Neurological Disorders. *Mendeley*. <https://doi.org/10.1007/978-3-030-97845-7>
- Nash, C., Nair, R., Naqvi, S. (2022). Machine Learning and ADHD Mental Health Detection - A Short Survey. *2022 25th International Conference on Information Fusion (FUSION)*. <https://doi.org/10.23919/FUSION49751.2022.9841277>
- Nogay, H., Adeli, H. (2020). Machine learning (ML) for the diagnosis of autism spectrum disorder (ASD) using brain imaging. *Reviews in the Neurosciences*. <https://doi.org/10.1515/revneuro-2020-0043>
- Rabelo-da-Ponte, F., de Azevedo Cardoso, T., Kapczinski, F., et al. (2023). The Use of Artificial Intelligence to Identify Trajectories of Severe Mental Disorders. *Digital Mental Health*. https://doi.org/10.1007/978-3-031-10698-9_13
- Raju, N., Madhavi, K., Sravan Kumar, G., et al. (2019). Prognostication of autism spectrum disorder (ASD) using supervised machine learning models. *International Journal of Engineering and Advanced Technology*.
- Rivera, M., Teruel, M., Maté, A., et al. (2022). Diagnosis and prognosis of mental disorders by means of EEG and deep learning: a systematic mapping study. <https://doi.org/10.1007/s10462-021-09986-y>
- Roy, Y., Banville, H., Alburquerque, I., et al. (2019). Deep learning-based electroencephalography analysis: a systematic review. <https://doi.org/10.1088/1741-2552/ab260c>

- Sadeghi, D., Shoeibi, A., Ghassemi, N., et al. (2022). An overview of artificial intelligence techniques for diagnosis of Schizophrenia based on magnetic resonance imaging modalities: Methods, challenges, and future works. *Computers in Biology and Medicine*. <https://doi.org/10.1016/j.compbiomed.2022.105554>
- Sadiq, M., Akbari, H., Siuly, S., et al. (2021). A novel computer-aided diagnosis framework for EEG-based identification of neural diseases. <https://doi.org/10.1016/j.compbiomed.2021.104922>
- Samy Helmy, A., Samy Helmy, B. (2022). Role of Artificial Intelligence in Mental Wellbeing: Opportunities and Challenges. *Journal of Artificial Intelligence*. <https://doi.org/10.3923/jai.2022.1.8>
- Son, H., Lee, D., Joung, Y., et al. (2021). A novel approach to diagnose ADHD using virtual reality. *International Journal of Web Information Systems*. <https://doi.org/10.1108/IJWIS-03-2021-0021>
- Song, J., Yoon, N., Jang, S., et al. (2020). Neuroimaging-based deep learning in autism spectrum disorder and attention-deficit/hyperactivity disorder. *Journal of the Korean Academy of Child and Adolescent Psychiatry*. <https://doi.org/10.5765/jkacap.200021>
- Sun, J., Dong, Q., Wang, S., et al. (2023). Artificial intelligence in psychiatry research, diagnosis, and therapy. *Asian Journal of Psychiatry*. <https://doi.org/10.1016/j.ajp.2023.103705>
- Tachmazidis, I., Chen, T., Adamou, M., et al. (2021). A hybrid AI approach for supporting clinical diagnosis of attention deficit hyperactivity disorder (ADHD) in adults. *Health Information Science and Systems*. <https://doi.org/10.1007/s13755-020-00123-7>
- Tanwar, P., Sharma, A. (2021). Machine learning techniques for autism spectrum disorder (ASD) detection. *International Journal of Forensic Engineering*. <https://doi.org/10.1504/ijfe.2021.10042591>
- Tutun, S., Johnson, M., Ahmed, A., et al. (2023). An AI-based Decision Support System for Predicting Mental Health Disorders. *Information Systems Frontiers*. <https://doi.org/10.1007/s10796-022-10282-5>
- Velarde-Incháustegui, M., Ignacio-Espíritu, M., Cárdenas-Soza, A. (2021). Diagnóstico de Trastorno del Espectro Autista-TEA, adaptándonos a la nueva realidad, Telesalud. <https://doi.org/10.20453/rnp.v84i3.4034>
- Venkatasubramanian, G. (2022). Machine Learning-based Diagnosis of Autism Spectrum Disorder Using Brain Imaging. *iScience Notes*. 10.22580/iSciNoteJ7.7.4
- Vishal, V., Singh, A., Jinila, Y., et al. (2022). A Comparative Analysis of Prediction of Autism Spectrum Disorder (ASD) using Machine Learning. 2022 6th International Conference on Trends in Electronics and Informatics, ICOEI 2022 - Proceedings. <https://doi.org/10.1109/ICOEI53556.2022.9777240>

- Wright, K. (2021). Brain Imaging for Autism Diagnosis. *Physics*. <https://doi.org/10.1103/physics.14.44>
- Yadav, K., Hasija, Y. (2022). Artificial Intelligence and Technological Development in Behavioral and Mental Healthcare. 2022 International Conference for Advancement in Technology (ICONAT). <https://doi.org/10.1109/ICONAT53423.2022.9726100>
- Yan, W., Ruan, Q., Jiang, K. (2022). Challenges for Artificial Intelligence in Recognizing Mental Disorders. *Diagnostics*. <https://doi.org/10.3390/diagnostics13010002>
- Yin, W., Li, L., Wu, F. (2022). Deep learning for brain disorder diagnosis based on fMRI images. *Neurocomputing*. 10.1016/j.neucom.2020.05.113
- Yin, W., Mostafa, S., Wu, F. (2021). Diagnosis of Autism Spectrum Disorder Based on Functional Brain Networks with Deep Learning. *Journal of Computational Biology*. <https://doi.org/10.1089/cmb.2020.0252>
- Zahia, S., Garcia-Zapirain, B., Saralegui, I., et al. (2020). Dyslexia detection using 3D convolutional neural networks and functional magnetic resonance imaging. *Computer Methods and Programs in Biomedicine*. <https://doi.org/10.1016/j.cmpb.2020.105726>
- Zhang, L., Wang, M., Liu, M., et al. (2020). A Survey on Deep Learning for Neuroimaging-Based Brain Disorder Analysis. *Frontiers in Neuroscience*. <https://doi.org/10.3389/fnins.2020.00779>
- Zhang, W., Yang, C., Cao, Z., et al. (2023). Detecting individuals with severe mental illness using artificial intelligence applied to magnetic resonance imaging. <https://doi.org/10.1016/j.ebiom.2023.104541>
- Zhang, X., Wang, R., Sharma, A., et al. (2021). Artificial intelligence in cognitive psychology – Influence of literature based on artificial intelligence on children’s mental disorders. *Aggression and Violent Behavior*. <https://doi.org/10.1016/j.avb.2021.101590>
- Zhou, S., Zhao, J., Zhang, L. (2022). Application of Artificial Intelligence on Psychological Interventions and Diagnosis: An Overview. *Frontiers in Psychiatry*. <https://doi.org/10.3389/fpsy.2022.811665>

Los sistemas de información y su influencia en las estrategias ambientales y el rendimiento organizacional

Enrique Ismael Meléndez Ruiz¹, Demian Abrego Almazán²,
José Melchor Medina Quintero³

**enrique.melendez@ulsavictoria.edu.mx; dabrego@docentes.uat.edu.mx;
jmedina@docentes.uat.edu.mx**

¹ Profesor-investigador de tiempo completo, Universidad La Salle Victoria, Tamaulipas, 87027, Victoria, México

³ Profesor-investigador de tiempo completo, Universidad Autónoma de Tamaulipas, Tamaulipas, 87027, Victoria, México

³ Profesor-investigador de tiempo completo, Universidad Autónoma de Tamaulipas, Tamaulipas, 87027, Victoria, México

DOI: 10.17013/risti.54.52-68

Resumen: La inquietud sobre el deterioro ambiental ha crecido de manera alarmante, ante ello, las empresas se han visto presionadas por aplicar procesos tecnológicos que cumplan con aspectos ambientales, siendo los sistemas de información con enfoque verdes uno de ellos. El objetivo del estudio es analizar cómo los sistemas de información verdes (SIV) influyen en las estrategias ambientales y en el rendimiento organizacional de las empresas manufactureras mexicanas. En el estudio cuantitativo se analizó un modelo jerárquico de segundo orden, mediante Modelado de Ecuaciones Estructurales basado en mínimos cuadrados parciales (PLS). La muestra recolectada fue de 99 gerentes de empresas medianas y grandes mediante un cuestionario. Se detecta que los SIV juegan un papel crucial en el crecimiento de las empresas, como herramienta para mejorar sus operaciones y al aspecto económico mediante la reducción de costos, pero al mismo tiempo, a cuestiones ambientales al tener la capacidad de reducir la contaminación emitida.

Palabras-clave: Sistemas de información verdes; estrategias ambientales; rendimiento organizacional; PLS; modelo de segundo orden.

Information systems and their influence on environmental strategies and organizational performance

Abstract: Concern about environmental degradation has been growing at an alarming rate, and as a result, companies have been pressured to apply technological processes that comply with environmental aspects, and green information systems are one of them. The objective of the study is to analyze how green information

systems (GIS) influence environmental strategies and organizational performance in Mexican manufacturing companies. In the quantitative study, a second-order hierarchical model was analyzed using Partial Least Squares (PLS) Structural Equation Modelling. The collected sample consisted of 99 managers of medium and large companies by questionnaire. It was found that GISs play a crucial role in the growth of companies, as a tool to improve their operations and to the economic aspect by reducing costs, but at the same time, to environmental issues by having the ability to reduce the pollution emitted.

Keywords: Green information systems; environmental strategies; organizational performance; PLS; higher-order models.

1. Introducción

Hoy en día, para las organizaciones la cuestión ambiental se ha convertido en componente relevante de su quehacer diario, a tal grado que se ven en la necesidad de reconsiderar cómo producen y envían productos y servicios (Sarkis et al., 2013). Como resultado, existe una tendencia hacia la adopción de tecnologías y desarrollo de estrategias para el cuidado ambiental que involucren un equilibrio en la búsqueda de sus intereses económicos con la responsabilidad hacia la sociedad y el medioambiente (Yoon, 2018). Para lograrlo, la gerencia se ha apoyado en el uso de las tecnologías de información (TI), ya que les permite mejorar su rendimiento operacional - ambiental y a su vez, se traslada directamente en una mejora substancial del rendimiento organizacional (Feng et al., 2018).

Uno de los tipos de TI más frecuentemente utilizados para llevar a cabo esta tarea, se les ha denominado sistemas de información verdes (SIV), ya que además de sus funciones estándar, también tienen el propósito de minimizar las emisiones contaminantes, el desperdicio de materia prima, de recursos naturales, mejorar la eficiencia de los procesos operativos y minimizar la huella ambiental emitida (Carberry et al., 2019). Sin embargo, la literatura sobre el tema muestra que su evaluación se ha abordado de forma limitada y desde las ventajas que ofrecen a cuestiones de carácter operativo, financiero o de procesos, pero no desde un punto de vista estratégico ambiental (Baggia et al., 2019; Lembcke et al., 2021). Cuestión similar para el estado del arte de investigaciones realizadas en México, pues la revisión también deja ver un vacío en los estudios que abordan el impacto sinérgico de los SIV y las estrategias ambientales (Loeser et al., 2017).

Por lo tanto, la presente investigación tiene como objetivo analizar como los SIV influyen en las estrategias ambientales y al rendimiento organizacional de empresas del sector manufacturero mexicano, para así proporcionar un estudio que contribuya a la academia relacionada a los negocios y los sistemas de información, tomando en cuenta que actualmente en México, no existen estudios que aborden los SIV como mejora para el rendimiento organizacional. Para ello, el presente documento consta de varias secciones, la primera se enfoca en describir la relevancia del tema, seguido por el apartado dedicado a la revisión de la literatura y defensa del modelo propuesto, para posteriormente abordar el método aplicado, continuando con los resultados del análisis de los datos. Por último, se expresan las conclusiones y limitaciones obtenidas que servirán de referencia para futuros trabajos.

2. Revisión de literatura

Sistemas de información verdes en las estrategias ambientales y en el rendimiento organizacional

Las empresas hoy en día caen en la necesidad de utilizar sistemas de información (SI) robustos, considerados como elementos clave que permiten el flujo de información de manera interorganizacional y con ellos, concretar sus procesos de negocios (Kalyar et al., 2019). Sin embargo, debido al deterioro ambiental ocasionado por la contaminación, las empresas se están viendo forzadas a adoptar estrategias para el cuidado hacia el medioambiente (Butler, 2011), mismas estrategias que requieren el soporte continuo de los SI para su consolidación (Meacham et al., 2013). Este tipo de sistemas utilizados para alcanzar los objetivos ambientales establecidos por las empresas han sido denominados sistemas de información verdes (SIV) (Jenkin et al., 2011). En el caso particular de la presente investigación se abordarán como herramientas de información empresariales para disminuir la contaminación emitida por las empresas (Baggia et al., 2019; Kalyar et al., 2019; Lembcke et al., 2021). Esta variable está definida por tres elementos clave: i) prevención de la contaminación, definido como la innovación y uso de SI para reducir las emisiones contaminantes (Khan y Qianli, 2017; Lembcke et al., 2021), ii) administración de productos, referida como actividades de gestión realizadas para minimizar el impacto ambiental asociado con el ciclo de vida del producto, a través del reciclaje, la manufactura verde y el diseño de nuevos productos verdes (Anthony, 2019; Mitra y Datta, 2014) y iii) desarrollo sustentable interno, conceptualizado como la mejora de la empresa a largo plazo en relación con el uso de tecnologías limpias (Li et al., 2016; Yang et al., 2017).

En cuanto a la relación de los SIV con el impacto a nivel organizacional de las empresas, diversos trabajos empíricos (Akhter, 2022; Baggia et al., 2019; Khan y Qianli, 2017; Lembcke et al., 2021; Nanath y Pillai, 2017; Yang et al., 2017, 2018, 2019) han demostrado la existencia de una relación directa e indirecta hacia diversas dimensiones que conforman al rendimiento organizacional. Molla, Cooper y Pittayachawan (2009) señalan que la capacidad que tiene una empresa de cumplir con las demandas gubernamentales, las presiones de los diversos grupos sociales y reducir su impacto hacia el medioambiente podría tener un efecto considerable en su competitividad. Esto permite destacar lo pertinente que ha demostrado ser el uso de los SIV (Araya-Guzmán, et al., 2019; Baggia et al., 2019; Khan y Qianli, 2017; Lembcke et al., 2021; Yang et al., 2019).

Como se puede advertir, el considerar con plenitud a los SIV la dirección de la empresa tendría la certeza de que no solo se reducirían los costos por ahorro de materiales y recursos, sino también, contarían con una mejora considerable en los procesos operacionales; esto mientras logran contribuir considerablemente a la protección al medioambiente. Por lo tanto, con base a la evidencia detectada, se propone la siguiente hipótesis de investigación.

H1: Los SIV tienen un impacto significativo y positivo sobre el rendimiento organizacional en las empresas manufactureras mexicanas.

Por otro lado, las tecnologías de información actualmente se consideran como la columna vertebral de la economía; indispensables para los negocios modernos y los procesos de

producción (Löser, 2015), mientras que, las cuestiones medioambientales han pasado a ser una de las presiones sociales más abordadas, debido a que las empresas contribuyen significativamente a su problemática, pero con su conocimiento, capacidades y recursos, también pueden jugar un papel clave en cambiar el curso de acción hacia un desarrollo sustentable, de esto parte el interés de las empresas por crear estrategias que involucren el desarrollo e implementación de nuevas prácticas ambientales (Loeser et al., 2017), dado que la creación de estos mecanismos es primordial, puesto que cualquier iniciativa descoordinada, que involucre una evolución de procesos será ineficiente.

Por ello, la formulación de estrategias ambientales es fundamental para llevar un cambio armonioso hacia la sustentabilidad empresarial. Considerando que las estrategias verdes se abordaron como el entendimiento mutuo de la alta dirección y los ejecutivos de TI en lo que respecta a las oportunidades y retos futuros que conciernen al cuidado del medioambiente y al crecimiento de la empresa a largo plazo (Loeser et al., 2017), y estarán seccionadas en dos elementos clave: i) estrategias organizacionales, como la perspectiva o visión de la empresa hacia el cumplimiento de objetivos ambientales (Danso et al., 2019; Loeser et al., 2017), y ii) estrategias funcionales, como aquellas que facilitan la efectividad y la eficiencia de las operaciones soportadas por los SI para el cumplimiento de los objetivos verdes (Chen et al., 2018). No obstante, la naturaleza y los beneficios de estas iniciativas son poco conocidos, por lo que la gerencia lucha por integrar elementos que ligen las tecnologías y las estrategias de cuidado ambiental (Loeser et al., 2017). De esta premisa, parten investigaciones (Acuña et al., 2017; Baggia et al., 2019; Danso et al., 2019; Loeser et al., 2017; Seidel et al., 2017; Yang et al., 2017) que buscan analizar la sinergia existente entre las tecnologías diseñadas o utilizadas para reducir el impacto medioambiental, y las estrategias organizacionales que buscan tanto cuidar el medioambiente como aprovechar oportunidades que generen una ventaja competitiva.

En cuanto a la relación en los constructos (SIV versus Estrategias Ambientales) las investigaciones de Acuña et al. (2017), Baggia et al. (2019), Danso et al. (2019), Loeser et al. (2017), Seidel et al. (2017) y Yang et al. (2017), establecen una relación positiva, si bien los resultados son diversos, queda claro que la literatura que estudia dicha relación es escasa. No obstante, esto no invalida la sinergia que estos dos elementos demuestran a la dirección de las empresas, ya que al contar con la infraestructura tecnológica que soporta las actividades que demandan sus estrategias, la gerencia tendrá la seguridad de que éstas logren culminarse en tiempo y forma. Por lo anteriormente descrito y de acuerdo con la evidencia referida en la literatura, se propone la siguiente hipótesis de investigación.

H2: El uso de SIV influye significativamente y de forma positiva en las estrategias ambientales de las empresas manufactureras mexicanas.

Las estrategias ambientales en el rendimiento organizacional

Las estrategias, en general, están comprendidas por actividades y procedimientos implementados por profesionales y ejecutivos de TI (Danso et al., 2019; Lo y Liao, 2021; Seidel et al., 2017), ya que la estrategia es un factor fundamental para el crecimiento organizacional y además motiva la actitud de trabajadores de TI para la adopción de SIV y así desarrollar ventajas medioambientales a largo plazo;

además de generar un impacto significativo en el rendimiento organizacional (Yang et al., 2015). En este sentido el rendimiento organizacional cuenta con un extenso número de conceptualizaciones y elementos que lo definen, asimismo, al ser una variable que siempre ha generado interés, diversos estudios han logrado identificar elementos clave que lo conforman como indicadores financieros (ganancias, retorno de inversiones, acciones, entre otros), de marketing (líneas de producto, penetración de mercado, ventas, entre otros) (Richard et al., 2009) y operativos (servicio al cliente, calidad del producto, productividad, administración de recursos, entre otros) (Inman et al., 2011).

Para el caso particular de esta investigación, se aborda el rendimiento organizacional como la habilidad de las empresas para alcanzar sus objetivos y metas al utilizar sus recursos de una manera efectiva y eficiente; compuesto por tres elementos clave: i) rendimiento operacional, entendido como la habilidad de la empresa para producir y entregar sus productos y servicios a los clientes de una manera profesional y eficiente (Masa'deh et al., 2017), ii) rendimiento financiero, enfocado en el retorno de las inversiones y la rentabilidad de la empresa (Danso et al., 2019; Zhang et al., 2021), y iii) rendimiento ambiental como la capacidad de las empresas de fabricación para reducir las emisiones contaminantes del aire, desechos efluentes y sólidos; además de la capacidad de disminuir el consumo de recursos y materiales tóxicos y peligrosos (Green et al., 2012).

Ahora bien, las estrategias ambientales han sido categorizadas de dos maneras, en primer término están las estrategias organizacionales, que consideran las oportunidades futuras y describen el papel de los SIV para alcanzar ventajas competitivas y el logro de los objetivos ambientales propuestos por la gerencia (Loeser et al., 2017) y, por otro lado, las estrategias funcionales son aquellas que describen algún plan ya concretado: por ejemplo, qué activos (personal, procesos, infraestructura, aplicaciones, presupuesto, entre otras) son requeridos para respaldar los objetivos ambientales, y dar como resultado una implementación efectiva de actividades tecnológicas - ecológicas (Loeser et al., 2017). Con respecto a la relación entre las variables estrategias ambientales y rendimiento organizacional investigaciones de Acuña et al. (2017), Baggia et al. (2019), Danso et al. (2019), Li et al. (2016), Loeser et al. (2017), Masa'deh et al. (2017), Seidel et al. (2017) y Zhang et al. (2021), dan como resultado que la relación es de forma positiva y significativa. Por ello, se infiere que el apoyo de la alta gerencia es un elemento clave en cualquier tipo de adopción e implementación de ideas innovadoras, incluyendo nuevas tecnologías, programas, políticas y actividades (Baggia et al., 2019), pues una vez que la dirección toma la sustentabilidad medioambiental como un imperativo estratégico, podrán implementar actividades para lograrlo (Loeser et al., 2017). Sin embargo, cualquier iniciativa ambiental descoordinada y que involucre la implementación de nuevas prácticas carecerá de un éxito significativo, si estos cambios no se apoyan en las estrategias, guías y políticas establecidas. Por lo tanto y con base a la evidencia empírica, se detona la siguiente hipótesis de investigación, mientras que la Figura 1 muestra el modelo propuesto.

H3: Las estrategias ambientales influyen significativa y positivamente sobre el rendimiento organizacional de las empresas manufactureras mexicanas.

3. Metodología

El presente estudio aborda un enfoque cuantitativo del tipo correlacional, exploratorio. El procedimiento seguido consistió en efectuar una revisión de literatura relacionada con el tema para desarrollar un cuestionario y fundamentar las hipótesis propuestas. Posteriormente a la creación del cuestionario, este fue validado mediante la participación de expertos e investigadores en el tema, cuyas sugerencias fueron incorporadas al instrumento de recolección, y como resultado se obtuvo un cuestionario conformado por 7 preguntas generales y 43 ítems en una escala tipo Likert de 7 puntos, donde uno corresponde a “totalmente en desacuerdo” y a 7 “totalmente de acuerdo”.

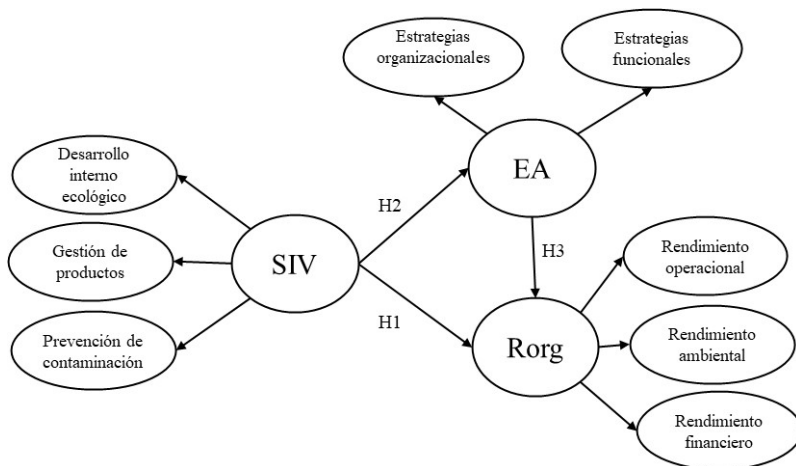


Figura 1 – Modelo teórico propuesto. Fuente: elaboración propia a partir de la literatura.

En cuanto a la recolección de los datos, fue de manera presencial a conveniencia durante el segundo semestre del 2022, en empresas del sector manufacturero de los estados mexicanos de Aguascalientes, Ciudad de México, Nuevo León, Querétaro y Tamaulipas. El tamaño de la muestra requerida era de 289 empresas manufactureras con un nivel de confianza del 95% y un margen de error de 5%. Lo recopilado fue de 99 observaciones válidas (34%), no obstante, se realizó un análisis que permitiera determinar si la muestra recolectada obtendría valores estadísticamente significativos que permitan inferir un resultado válido, para ello se aplicó la propuesta de Faul et al. (2009) a través de la herramienta estadística G*Power 3.1.9.7, aplicando una prueba estadística para regresiones lineales múltiples, con 2 predictores, una potencia de 0.9, un efecto de f^2 de 0.15 y un Alfa de 0.05, el resultado indicó que se requerían de al menos 90 observaciones, lo cual permite concluir que la muestra recolectada es la suficiente para comprobar las relaciones inferenciales propuestas en este estudio. Por último, el análisis estadístico aplicado fue mediante el empleo del modelado de ecuaciones estructurales de orden superior mediante la técnica de mínimos cuadrados parciales (PLS-SEM, por sus siglas en inglés).

4. Resultados

En primer término, se muestran los datos descriptivos. Del total de encuestas recolectadas, 28 son del estado de Tamaulipas, 38 de Nuevo León, 10 de Ciudad de México, 15 de Querétaro, 5 de Aguascalientes y 4 del Estado de México. Mientras que por tipo de empresa (17%) corresponden a la industria alimentaria, (12%) a la automotriz, (12%) metálica básica, (12%) manufactura de maquinaria y equipos, (10%) a papel, el resto pertenece a otros sectores minoritarios. En relación con los datos generales de las empresas, se comenta que el 52% son empresas de tamaño grande (> 251 empleados), mientras que el resto (48%) está compuesto por empresas medianas, es decir, de entre 50 y 250 empleados, mientras que su edad promedio es de 36 años de antigüedad. Por lo que respecta a los individuos que contestaron la encuesta. Se identificó que el 62% de la unidad de información cuenta con algún puesto gerencial o de alto mando (desde directivo hasta dueño de la empresa), mientras que el resto está conformado por administradores (38%). Además de que, en su mayoría (64%), tienen alrededor de entre 6 a 10 años de experiencia en su puesto, y un 19% entre 0 a 5 años de antigüedad.

Por otra parte, para probar las hipótesis propuestas, se utilizó PLS-SEM a fin de evaluar las relaciones entre las variables y el poder predictivo del modelo. Para ello se siguió el proceso de estimación de un modelo de componentes jerárquicos (HCMs, por sus siglas en inglés) aplicando el enfoque de dos etapas para modelos de tipo reflectivo-reflectivo de Sarstedt et al. (2019), el cual consiste en: [etapa 1] i) diseñar el modelo sin constructos de orden superior (HOCs) y evaluar el modelo de medida con los constructos de orden inferior (LOCs), ii) obtener las ponderaciones de las variables latentes o LOCs [estrategias organizacionales (EO), estrategias funcionales (EF), rendimiento operacional (ROPE), rendimiento ambiental (RA), rendimiento financiero (RF), prevención de contaminación (PC), gestión de productos (GP), desarrollo interno ecológico (DIE)], [etapa 2] iii) rediseñar el modelo incluyendo los constructos HOCs medidos mediante las ponderaciones obtenidas en paso anterior (Figura 2), iv) evaluar el modelo de medida rediseñado, y v) evaluar el modelo estructural.

Una vez diseñado el modelo (paso 1), se evaluó el modelo de medida a través de la fiabilidad de los indicadores, la validez convergente y discriminante de las variables en primer orden. Para aceptar la fiabilidad de los indicadores, éstos deben contar con una carga factorial de ≥ 0.707 ; solo PC3 no cumplió. Por otro lado, para los criterios de fiabilidad interna de los constructos, la fiabilidad compuesta (ρ_c) debe contar con un valor mínimo de 0.7 (Hair et al., 2017; Ringle et al., 2009). Por último, para reconocer la validez convergente (AVE) de las variables, esta debe contar con valores superiores a 0.5 (Ringle et al., 2009), la Tabla 1 muestra lo obtenido.

Por su parte, para probar la validez discriminante del modelo en primer orden, se utilizó el criterio HTMT, en la Tabla 2 se muestra que se cumple, pues los valores son inferiores a 0.90 (Henseler et al., 2015). Ahora bien, el paso 2 consiste en obtener las ponderaciones de las variables latentes (LOC's) para con ello, poder reespecificar el modelo (paso 3, ver Figura 2), una vez realizado se procede a evaluar el modelo de medida a través de la fiabilidad interna, validez convergente y discriminante de los indicadores y constructos que lo componen (paso 4). En la Tabla 3 se muestra que todos los indicadores cumplen con lo sugerido por Hair et al. (2017) y Ringle et al. (2009), caso igual para la validez discriminante.

HOC	LOC	ρ_c	AVE	Aspectos evaluados	Referencias
Estrategias ambientales (EA)	Estrategias organizacionales (EO)	0.940	0.758	Potencial y cumplimiento de las estrategias ambientales, Involucramiento gerencial, Velocidad de respuesta hacia áreas de oportunidad.	(Löser, 2015; Loeser et al., 2017; Wu y Wu, 2014)
	Estrategias funcionales (EF)	0.946	0.813	Distribución de recursos, Planeación estratégica ambiental, Preferencia hacia objetivos ambientales.	(Chen et al., 2018; Loeser et al., 2017; Wu y Wu, 2014; Seman, et al., 2019).
Sistemas de información verde (SIV)	Prevención de contaminación (PC)	0.915	0.610	Reducción de consumo de materiales y recursos naturales, de desperdicio de materiales, de uso de materiales peligrosos, monitoreo de emisiones.	(Anthony, 2019; Baggia et al., 2019; Khan y Qianli, 2017; Li et al., 2016; Meacham et al., 2013; Mitra y Datta, 2014; Yang et al., 2017).
	Gestión de productos (GP)	0.931	0.731	Adquisición de materiales verdes, distribución de productos, diseño y manufactura verde, reciclaje.	(Anthony, 2019; Baggia et al., 2019; Khan y Qianli, 2017; Li et al., 2016; Meacham et al., 2013; Mitra y Datta, 2014; Yang et al., 2017).
	Desarrollo interno ecológico (DIE)	0.875	0.583	Facilitar operaciones ecológicas y el apoyo gerencial ecológico.	(Anthony, 2019; Baggia et al., 2019; Khan y Qianli, 2017; Li et al., 2016; Mitra y Datta, 2014; Yang et al., 2017).

HOC	LOC	pc	AVE	Aspectos evaluados	Referencias
Rendimiento Organizacional (RORG)	Rendimiento operacional (ROPE)	0.935	0.672	Eficiencia en manufactura de productos, en la gestión del transporte de productos, Incremento en el desempeño laboral, Reducción de riesgos operacionales, Desarrollo de nuevos productos.	(Feng et al., 2018; Inman et al., 2011; Mitra y Datta; 2014; Yang et al., 2018).
	Rendimiento ambiental (RA)	0.927	0.719	Retorno de inversión, Crecimiento financiero, Ahorro por uso de materiales	(Anthony, 2019; Meacham et al., 2013; Yang et al., 2017, 2019).
	Rendimiento financiero (RF)	0.947	0.781	Reutilización de materiales, Preservación ambiental, Control en el uso de recursos y energía, Reducción de emisiones contaminantes.	(Anthony, 2019; 2014; Meacham et al., 2013; Yang et al., 2017, 2019)

Tabla 1 – Fiabilidad y validez convergente de los constructos en primer orden (LOCs)

	DIE	EF	EO	GP	PC	RA	RF	ROPE
DIE	---							
EF	0.741							
EO	0.704	0.891						
GP	0.810	0.700	0.616					
PC	0.822	0.733	0.706	0.864				
RA	0.675	0.680	0.638	0.636	0.711			
RF	0.715	0.534	0.449	0.598	0.620	0.696		
ROPE	0.721	0.629	0.513	0.648	0.693	0.754	0.808	---

Tabla 2 – Validez discriminante criterio HTMT para el modelo de primer orden (LOCs)

HOCs	Indicadores	Consistencia Interna y validez convergente			Validez discriminante		
		Cargas	AVE	ρ_c	Criterio HTMT		
					EA	RORG	SIV
Estrategias Ambientales (EA)	Estrategias organizacionales (EO)	0.949	0.910	0.953	--		
	Estrategias funcionales (EF)	0.959					
Rendimiento organizacional (RORG)	Rendimiento operacional (ROPE)	0.914	0.795	0.921	0.702	--	
	Rendimiento ambiental (RA)	0.874					
	Rendimiento financiero (RF)	0.886					
Sistemas de información verde (SIV)	Prevención de contaminación (PC)	0.917	0.823	0.933	0.817	0.845	--
	Gestión de productos (GP)	0.911					
	Desarrollo interno ecológico (DIE)	0.893					

Tabla 3 – Resultado de la estimación de la validez convergente y discriminante del modelo rediseñado 2do. orden.

Antes de estimar el modelo estructural (paso 5), se evalúa su ajuste (Henseler et al., 2015; Ringle et al., 2015). Para ello, se efectuó el proceso bootstrapping con 5,000 submuestras, con una cola y un intervalo de confianza basado en percentil Bootstrap. La figura 1 muestra un valor de 0.057 en el SRMR, situándose en el umbral permitido (< 0.08), de igual manera para los indicadores d_{ULS} y d_G al contar con valores inferiores al intervalo de confianza del 99% (Henseler et al., 2015). Por lo tanto, el modelo presenta un adecuado ajuste y con ello se puede continuar con el proceso de estimación. Por otra parte, dentro del análisis del modelo estructural se debe determinar el poder explicativo del modelo, es decir, la cantidad de varianza (R^2) generada en la variable dependiente a través de los constructos independientes. Para las estrategias ambientales los SIV generaron una R^2 de 0.540, catalogándose como un poder explicativo moderado. Mientras que para el rendimiento organizacional el efecto conjunto de los SIV y las estrategias ambientales explican un 57% de la varianza de dicha variable.

Asimismo, el rendimiento organizacional presenta un valor en f^2 de 0.030 cuando se omite la variable estrategias ambientales y un 0.413 para SIV; resultados catalogados como pequeño y alto respectivamente, indicando que la eliminación de las estrategias ambientales no provocaría un cambio significativo en la explicación de su R^2 . Como última etapa para la modelización PLS-SEM, se estimaron los coeficientes *path* del modelo estructural, en la Figura 2 se presenta los resultados, en donde el atributo de mayor importancia en el rendimiento organizacional de acuerdo con el coeficiente *path* y su nivel de significancia son los SIV.

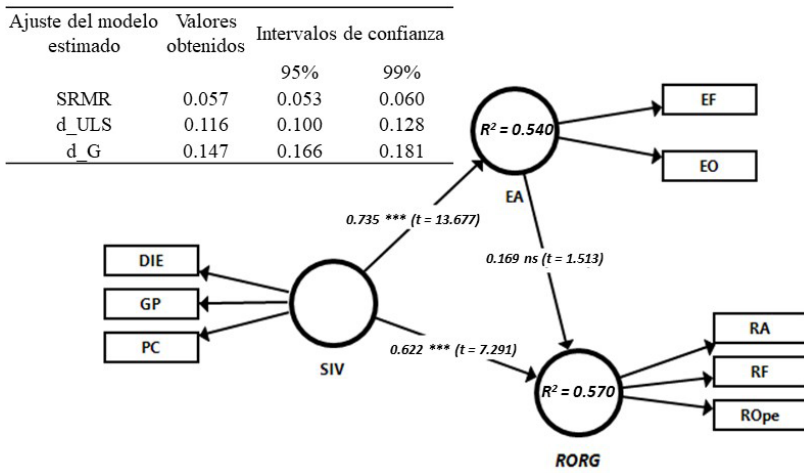


Figura 2 – Resultado del modelo.
 Nota: p valor < 0.000 = ***; ns: no significativo.
 Fuente: elaboración propia.

5. Discusión

Con base a lo expuesto en la Figura 2 se procede a realizar el contraste de hipótesis planteadas. En primer término se menciona la hipótesis (H1) que representa la relación existente entre los SIV y el rendimiento organizacional, la cual obtuvo un valor beta ($\beta = 0.622$) muy significativa ($p < 0.000$), por lo cual se acepta, siendo similar a estudios aplicados a empresas del sector manufacturero, bajo diferentes perspectivas, países y culturas como Pakistán, Estados Unidos, Corea del Sur, Japón, entre otros (Anthony, 2019; Khan y Qianli, 2017; Yang et al., 2019), los cuales lograron explicar la relación existente entre el uso de SIV y su influencia para obtener un mayor rendimiento organizacional desde un enfoque ambiental y financiero. Lo obtenido permite conocer las cualidades que los SIV ofrecen hacia los beneficios organizacionales, así como el poder reducir significativamente la huella de carbón generada por las empresas, esto a través de su capacidad por minimizar la contaminación emitida al poder llevar un control sobre los procesos de fabricación de las plantas, el consumo de materiales, energía y recursos naturales, así como del desperdicio de materia prima, mientras llevan un control sobre los procesos operativos de la empresa, esto se trasladaría directamente hacia una mejora substancial en el rendimiento operativo y a su vez impactaría, hasta un cierto grado, las remuneraciones de las empresas.

Ahora bien, la relación existente entre los SIV y las estrategias ambientales, es decir, la hipótesis H2, los hallazgos muestran un valor alto en su β (0.735) y un nivel de significancia de $p < 0.000$. Por lo tanto, se acepta. El resultado de esta relación es similar con los estudios de Acuña et al. (2017), Anthony (2020), Baggia et al. (2019), Green et al. (2012) provenientes de países tanto con economías emergentes como desarrollados; los cuales también identificaron una relación existente entre las TI con enfoque ambiental y las estrategias para el cuidado ecológico, determinando que, las tecnologías de

información con enfoque verde logran transformar ciertos procesos organizacionales y orientarlos hacia la culminación de metas ambientales, esta variedad de estudios que han abordado a las TI como herramientas que coadyuvan a la culminación de estrategias ambientales han logrado catalogar estas tecnologías como esenciales para alcanzar los objetivos medioambientales de las empresas. No obstante, es importante destacar que no basta con solo proponer o plantear estas estrategias, sino que es fundamental darles la importancia y la prioridad adecuada para llevar a cabo las acciones necesarias y así realmente aporten significativamente a los resultados tangibles de las empresas. Esta última aseveración abre la puerta a la tercera y última hipótesis de este estudio.

La tercera hipótesis (H3) corresponde al efecto que tienen las estrategias ambientales en el rendimiento organizacional de las empresas manufactureras. Los resultados obtenidos para la hipótesis planteada sugieren un efecto positivo ($\beta = 0.169$) pero no significativo ($p > 0.05$), por lo que se rechaza, siendo contrario a las investigaciones de Cifuentes-Bedoya et al. (2021), Acuña et al. (2017), Li et al. (2016), Seidel et al. (2017) y Yang et al. (2015) quienes manifiestan que este tipo de estrategias favorecen a la mejora del rendimiento organizacional, como son el florecimiento de actividades para el cuidado ambiental, mayor rendimiento en las operaciones de negocios, de manufactura, como también en el ámbito financiero a través de la reducción de los costos de energía y desperdicio de materiales. Asimismo, son diferentes a los trabajos de Green et al. (2012), Li et al. (2016) y Loeser et al. (2017), puesto que demuestran que las empresas, al aplicar estrategias que involucren a una cadena de suministro ecológica en conjunto con un soporte técnico - administrativo correcto y de calidad en los sistemas de información con enfoque verde, así como del involucramiento constante de la alta gerencia, pueden generar mejoras en forma de beneficios financieros, operativos y de desempeño medioambiental, como reducción de costos, innovación de procesos, mayor gama de productos, una ventaja competitiva a largo plazo, mayor eficiencia en las rutas de envío de productos, entre otros.

No obstante, la investigación concuerda con lo expuesto por Galindo-Manrique et al., (2021), según los cuales las empresas provenientes de economías emergentes suelen contaminar más que sus semejantes en países desarrollados debido a la menor presión social y a la insuficiencia de recursos, pues los datos analizados infieren que las empresas estudiadas no desarrollan o aplican del todo las estrategias ambientales, y solo lo hacen por cumplir con requisitos legales; resultado que también puede ser afectado por el tipo de literatura consultada, la cual, en su mayoría fue impulsada en países desarrollados, y que, a diferencia con México (país con economía emergente), podrían tener una cultura con mayor concientización ambiental.

6. Conclusiones

El deterioro ambiental provocado por las empresas y las malas prácticas ambientales provocan cantidades innumerables de contaminación y dispendio de recursos y debido a la incertidumbre de las actividades de protección ambiental, las empresas no optan por adoptar estas opciones. Por lo tanto, lo obtenido presenta de manera empírica el efecto que tienen los SIV en las estrategias ambientales y cómo impactan en el rendimiento organizacional, cumpliendo con el objetivo principal de esta investigación, también se logra contrastar la duda acerca de las empresas al momento de considerar el optar por

estrategias ambientales, ya que un alto nivel de involucramiento por la alta dirección y la gerencia les permite reconocer su potencial lucrativo, al poder responder de manera oportuna a señales de áreas de oportunidad respecto al cuidado ambiental, considerando ampliamente el uso de tecnologías de información. También permite reducir la incertidumbre sobre los impactos económicos cuando se considera desarrollar y aplicar estrategias o iniciativas de protección medioambiental en los procesos de negocio soportadas por las tecnologías de información, esto motivaría tanto a los ejecutivos de negocios, tomadores de decisiones y hasta ejecutivos de TI a desarrollar o fomentar los esfuerzos o posturas medioambientales en las empresas, y de esa manera poder cosechar los beneficios de las inversiones tanto en tecnologías como en estrategias verdes.

Sin embargo, también muestra que las empresas estudiadas no logran visualizar o establecer un vínculo claro entre las estrategias ambientales con los posibles beneficios organizacionales, ya que el rendimiento organizacional no presenta cambios considerables bajo la inclusión o exclusión de las estrategias ambientales. Esto permite inferir que, las empresas estudiadas, deben ser más conscientes de los potenciales beneficios que el desarrollo de estrategias ambientales aportan no solo al medioambiente, sino al rendimiento organizacional abordado desde diversos aspectos, desde su reducción de costos por multas por accidentes ambientales, uso de energía y materia prima, mejora en la eficiencia de las operaciones generales de las plantas y hasta certificar a la empresa como socialmente responsable, lo que contribuirá también a mejorar considerablemente su imagen corporativa.

Por último, como todo estudio de investigación cuenta con diversas limitaciones. Una de ellas es representada por el periodo de tiempo, al ser una fotografía de un momento dado. Por otra parte, se propone analizar a los sistemas de información verdes bajo otras perspectivas distintas (ej., calidad del servicio del staff de tecnologías, calidad de la información y sistema, satisfacción del usuario, soluciones, diseño del sistema, actitud de uso, usabilidad, entre otros), ya que para este estudio se evaluaron concretamente solo por su capacidad de prevenir la contaminación, gestión de productos ecológicos y desarrollo interno ecológico de las empresas.

Referencias

- Acuña, N., Figueroa, L., & Wilches, M. J. (2017). Influencia de los Sistemas de Gestión Ambiental ISO 14001 en las organizaciones: caso estudio empresas manufactureras de Barranquilla. *Ingeniare. Revista Chilena de Ingeniería*, 25(1), 143–153. <https://doi.org/10.4067/S0718-33052017000100143>.
- Akhter, A. (2022). Impact of accounting information system on organizational performance: Private commercial banks of bangladesh. *International Journal of Scientific and Research Publications*, 12(4), 307-314. <http://dx.doi.org/10.29322/IJSRP.12.04.2022.p12443>.
- Anthony, B. (2019). Green information system integration for environmental performance in organizations: An extension of belief-action-outcome framework and natural resource-based view theory. *Benchmarking-an international journal*,

26(3), 1033–1062. <https://doi.org/10.1108/BIJ-05-2018-0142>.

- Anthony, B. (2020). Green information systems refraction for corporate ecological responsibility reflection in ICT based firms: explicating technology organization environment framework. *Journal of Cases on Information Technology (JCIT)*, 22(1), 14-37. <https://10.4018/JCIT.2020010102>.
- Araya-Guzmán, S., Bravo, C. H., Ramírez-Correa, P., & Salazar, A. B. (2019). Explorando la relación entre gestión del conocimiento y el rendimiento organizativo en instituciones de educación superior universitaria. *RISTI - Revista Ibérica de Sistemas e tecnologias de Informação*, (E17), 947-959.
- Baggia, A., Maletic, M., Znidarsic, A., & Brezavscek, A. (2019). Drivers and Outcomes of Green IS Adoption in Small and Medium-Sized Enterprises. *Sustainability*, 11(6). <https://doi.org/10.3390/su11061575>.
- Butler, T. (2011). Compliance with institutional imperatives on environmental sustainability: Building theory on the role of Green IS. *Journal of strategic information systems*, 20(1, SI), 6–26. <https://doi.org/10.1016/j.jsis.2010.09.006>.
- Carberry, E., Bharati, P., Levy, D., & Chaudhury, A. (2019). Social movements as catalysts for corporate social innovation: Environmental activism and the adoption of green information systems. *Business & Society*, 58(5), 1083-1127. <https://doi.org/10.1177/2F0007650317701674>.
- Chen, C., Yu, C., & Hu, J. (2018). Constructing performance measurement indicators to suggested corporate environmental responsibility framework. *Technological Forecasting and Social Change*, 135, 33-43.
- Cifuentes-Bedoya, D., Lozada-Valencia, F., Segovia-Borray, C. E., & Otalora-Murcia, E. (2021). La Responsabilidad Social Empresarial (RSE) y la Creación de Valor Compartido (CVC), ejes determinantes para la gestión de las PYMES. Una revisión bibliométrica. *RISTI - Revista Ibérica de Sistemas e Tecnologias de Informação*, (E43), 549-567.
- Danso, A., Adomako, S., Amankwah-Amoah, J., Owusu-Agyei, S., & Konadu, R. (2019). Environmental sustainability orientation, competitive strategy and financial performance. *Business Strategy and the Environment*, 28(5), 885-895.
- Faul, F., Erdfelder, E., Buchner, A., & Lang, A. G. (2009). Statistical power analyses using G* Power 3.1: Tests for correlation and regression analyses. *Behavior research methods*, 41(4), 1149-1160. <https://doi.org/10.3758/BRM.41.4.1149>.
- Feng, M., Yu, W., Wang, X., Wong, C. Y., Xu, M., & Xiao, Z. (2018). Green supply chain management and financial performance: The mediating roles of operational and environmental performance. *Business strategy and the Environment*, 27(7), 811-824.
- Galindo-Manrique, A., Pérez-Calderón, E., & Rodríguez-García, M. (2021). Eco-Efficiency and Stock Market Volatility: Emerging Markets Analysis. *Administrative*

- Sciences, 11(2), 36. <https://doi.org/10.3390/admsci11020036>.
- Green, K., Zelbst, P., Bhadauria, V., & Meacham, J. (2012). Do environmental collaboration and monitoring enhance organizational performance? *Industrial Management and Data Systems*, 112(2), 186–205. <https://doi.org/10.1108/02635571211204254>.
- Hair, J., Hult, G., Ringle, C., & Sarstedt, M. (2017). *A Primer on Partial Least Squares Structural Equation Modeling (PLS-SEM)*. 2nd Ed., Thousand Oakes, CA: Sage.
- Henseler, J., Ringle, C., & Sarstedt, M. (2015). A new criterion for assessing discriminant validity in variance-based structural equation modeling. *Journal of the academy of marketing science*, 43(1), 115-135. <https://doi.org/10.1007/s11747-014-0403-8>.
- Inman, R. Sale, R., Green, K., & Whitten, D., (2011). Agile manufacturing: Relation to JIT, operational performance and firm performance. *Journal of Operations Management*, 29, 343-355. <https://doi.org/10.1016/j.jom.2010.06.001>.
- Jenkin, T., McShane, L., & Webster, J. (2011). Green information technologies and systems: Employees' perceptions of organizational practices. *Business & Society*, 50(2), 266-314.
- Kalyar, M., Shoukat, A., & Shafique, I. (2019). Enhancing firms' environmental performance and financial performance through green supply chain management practices and institutional pressures. *Sustainability Accounting, Management and Policy Journal*, 11(2), 451 – 476. <https://doi.org/10.1108/SAMPJ-02-2019-0047>.
- Khan, S., Qianli, D. (2017). Impact of green supply chain management practices on firms' performance: an empirical study from the perspective of Pakistan. *Environmental Science and Pollution Research*, 24(20), 16829–16844. <https://doi.org/10.1007/s11356-017-9172-5>.
- Lembcke, T., Herrenkind, B., Nastjuk, I., & Brendel, A. (2021). Promoting Business Trip Ridesharing with Green Information Systems: A Blended Environment Perspective. *Transportation Research Part D: Transport and Environment*, 94, 102795. <https://doi.org/10.1016/j.trd.2021.102795>.
- Li, S., Jayaraman, V., Paulraj, A., & Shang, K. (2016). Proactive environmental strategies and performance: Role of green supply chain processes and green product design in the Chinese high-tech industry. *International Journal of Production Research*, 54(7), 2136–2151. <https://doi.org/10.1080/00207543.2015.1111532>.
- Lo, F., & Liao, P. C. (2021). Rethinking financial performance and corporate sustainability: Perspectives on resources and strategies. *Technological Forecasting and Social Change*, 162, 120346. <https://doi.org/10.1016/j.techfore.2020.120346>.
- Loeser, F., Recker, J., vom Brocke, J., Molla, A., & Zarnekow, R. (2017). How IT executives create organizational benefits by translating environmental strategies into Green IS initiatives. *Information Systems Journal*, 27(4), 503–553. <https://doi.org/10.1111/isj.12136>.
- Löser, F. (2015). *Strategic Information Systems Management for Environmental*

- Sustainability: Enhancing Firm Competitiveness with Green IS. <https://doi.org/http://dx.doi.org/10.14279/depositonce-4447>.
- Nanath, K., & Pillai, R. (2017). The influence of green is practices on competitive advantage: Mediation role of green innovation performance. *Information Systems Management*, 34(1), 3-19. <https://doi.org/10.1080/10580530.2017.1254436>.
- Masa'deh, R., Alananzeh, O., Algiatheen, N., Ryati, R., Albayyari, R., & Tarhini, A. (2017). The impact of employee's perception of implementing green supply chain management on hotel's economic and operational performance. *Journal of Hospitality and Tourism Technology*. <https://doi.org/10.1108/JHTT-02-2017-0011>.
- Meacham, J., Toms, L., Green, K., & Bhadauria, V. (2013). Impact of information sharing and green information systems. *Management Research Review*, 36(5), 478–494. <https://doi.org/10.1108/01409171311327244>.
- Mitra, S., & Datta, P. (2014). Adoption of green supply chain management practices and their impact on performance: An exploratory study of Indian manufacturing firms. *International Journal of Production Research*, 52(7), 2085–2107. <https://doi.org/10.1080/00207543.2013.849014>.
- Molla, A., Cooper, V., & Pittayachawan, S. (2009). IT and Eco-sustainability: Developing and validating green IT readiness model. *ICIS 2009 Proceedings*, 141, 1–17.
- Richard, P., Devinney, T., Yip, G., & Johnson, G. (2009). Measuring organizational performance: Towards methodological best practice. *Journal of Management*, 35(3), 718–804. <https://doi.org/10.1177/0149206308330560>.
- Ringle, C., Götz, O., Wetzels, M., & Wilson, B. (2009). On the use of formative measurement specifications in structural equation modeling: A Monte Carlo simulation study to compare covariance-based and partial least squares model estimation methodologies. *METEOR Research Memoranda (RM/09/014)*. https://papers.ssrn.com/Sol3/papers.cfm?abstract_id=2394054.
- Ringle, C. M., Wende, S., & Becker, J. (2015). *SmartPLS 3*. Bönningstedt: SmartPLS. <https://www.smartpls.com>.
- Sarkis, J., Koo, C., & Watson, R. T. (2013). Green information systems y technologies - this generation and beyond: Introduction to the special issue. *Information systems frontiers*, 15(5), 695–704. <https://doi.org/10.1007/s10796-013-9454-5>.
- Sarstedt, M., Hair Jr, J., Cheah, J., Becker, J., & Ringle, C. (2019). How to specify, estimate, and validate higher-order constructs in PLS-SEM. *Australasian Marketing Journal (AMJ)*, 27(3), 197-211. <https://doi.org/10.1016/j.ausmj.2019.05.003>.
- Seidel, S., Bharati, P., Watson, R., Boudreau, M. Kruse, L., Karsten, H., Melville, N., Toland, J., Fridgen, G., Albizri, A., Butler, T., Guzman, I., Lee, H., Rush, D., & Watts, S. (2017). The Sustainability Imperative in Information Systems Research. *Communications of the association for information systems*, 40(1). <https://doi.org/10.17705/1CAIS.04003>.
- Seman, N., Govindan, K., Mardani, A., Zakuan, N., Saman, M., Hooker, R., & Ozkul, S.

- (2019). The mediating effect of green innovation on the relationship between green supply chain management and environmental performance. *Journal of cleaner production*, 229, 115-127.
- Yang, J., Zhang, F., Jiang, X., & Sun, W. (2015). Strategic flexibility, green management, and firm competitiveness in an emerging economy. *Technological Forecasting and Social Change*, 101, 347–356. <https://doi.org/10.1016/j.techfore.2015.09.016>.
- Wu, S., & Wu, Y. (2014). The influence of enterprisers' green management awareness on green management strategy and organizational performance. *International Journal of Quality and Reliability Management*, 31(4), 455–476. <https://doi.org/10.1108/IJQRM-01-2013-0019>.
- Yang, Z., Sun, J., Zhang, Y., Wang, Y., & Cao, L. (2017). Employees' collaborative use of green information systems for corporate sustainability: motivation, effort and performance. *Information technology for development*, 23(3), 486–506. <https://doi.org/10.1080/02681102.2017.1335281>.
- Yang, Z., Sun, J., Zhang, Y., & Wang, Y. (2018). Peas and carrots just because they are green? Operational fit between green supply chain management and green information system. *Information Systems Frontiers*, 20(3), 627–645. <https://doi.org/10.1007/s10796-016-9698-y>.
- Yang, Z., Sun, J., Zhang, Y., & Wang, Y. (2019). Perceived fit between green IS and green SCM: Does it matter? *Information management*, 56(7). <https://doi.org/10.1016/j.im.2019.02.009>.
- Yoon, C. (2018). Extending the TAM for Green IT: A normative perspective. *Computers in Human Behavior*, 83, 129–139. <https://doi.org/10.1016/j.chb.2018.01.032>.
- Zhang, Y., & Wei, F. (2021). SMEs' charismatic leadership, product life cycle, environmental performance, and financial performance: A mediated moderation model. *Journal of Cleaner Production* (2021), 127147. <https://doi.org/10.1016/j.jclepro.2021.127147>.

Sistema Inteligente de Gestión de Semáforos en Tiempo Real

Yim Isaias Apestequi Florentino¹, Hugo Esteban Caselli Gismondi¹

yapestequi@uns.edu.pe; hcasellig@uns.edu.pe

¹ Universidad Nacional del Santa, Av. Pacífico 508, 02711, Nuevo Chimbote, Perú.

DOI: 10.17013/risti.54.69–87

Resumen: La gestión del tráfico vehicular es un desafío importante en las ciudades del mundo, pues involucra a la gestión de semáforos y el flujo de tráfico. El problema específico es la configuración de semáforos con asignaciones de tiempos fijos, no acorde al tiempo requerido por el flujo de tráfico real. El objetivo de este trabajo es proponer un sistema inteligente para gestionar en tiempo real el semáforo en una intersección vial; el cual se ajusta a las condiciones reales del tráfico que son la velocidad y densidad vehicular. Para ello, se desarrolló un algoritmo heurístico que toma en cuenta las características del tráfico y luego toma decisiones para asignar el tiempo de fase correspondiente. Pruebas experimentales con 15000 escenarios simulados permitieron estimar el tiempo de espera entre ciclos semaforicos. Los resultados mostraron una reducción del 18.3% de tiempo del ciclo con una mejora de 47 ciclos/hora respecto a los 39 ciclos/hora de un semáforo tradicional con tiempos de fase fijos.

Palabras-clave: Semáforo inteligente; flujo vehicular; algoritmo heurístico; simulación.

Intelligent Traffic Light Management System in Real Time

Abstract: The management of vehicular traffic poses a significant challenge in cities worldwide, as it involves the control of traffic lights and traffic flow. The specific issue lies in the configuration of traffic lights with fixed-time allocations, not in line with the time required by real traffic flow. The aim of this study is to propose an intelligent system for real-time management of traffic lights at an intersection, which adjusts to the actual traffic conditions, namely speed and vehicle density. To achieve this, a heuristic algorithm was developed, considering traffic characteristics and making decisions to allocate the corresponding phase time. Experimental tests with 15,000 simulated scenarios allowed for the estimation of waiting time between signal cycles. The results demonstrated an 18.3% reduction in cycle time with an improvement of 47 cycles/hour compared to the 39 cycles/hour of a traditional traffic light with fixed phase times.

Keywords: Smart traffic light; vehicular flow; heuristic algorithm; simulation.

1. Introducción

La gestión del tráfico vehicular se ha convertido en un gran desafío en ciudades del mundo con expansión demográfica, pues a mayor crecimiento poblacional, mayor demanda de transporte. Saus (2023) menciona que los patrones de expansión de las ciudades tienen un impacto en la efectividad del transporte público. En ese sentido, los gobiernos locales suelen descuidar la planificación del transporte, en medio de una creciente cantidad de vehículos (Ministerio de Seguridad Pública de China, 2023) y la inadecuada gestión del tráfico. Las emisiones de dióxido de carbono (CO₂) del parque automotor son una situación preocupante, sabiendo que el 90% de las emisiones de CO₂ están contribuyendo al cambio climático (Nikas et al., 2022). En cuanto al control de las emisiones de CO₂, en países de Latinoamérica como Colombia, Ecuador y Perú, las sugerencias de organismos internacionales de reemplazar vehículos que utilizan combustibles fósiles por vehículos eléctricos no se pueden implementar fácilmente (OCDE, 2011).

Respecto a la gestión del tráfico, los planes de gestión siguen perdiendo eficacia. Camargo (2018) menciona que el modelo “pico y placa” implementado en la ciudad de Bogotá, Colombia, en el año 2002, no ha mejorado el problema de la congestión vehicular. En el año 2002, había 500,000 automóviles registrados; para el año 2011, este número aumentó a 1,400,000 automóviles particulares. Caso similar sucedió en la ciudad de Lima, Perú; en el año 2019 se implementó el modelo “pico y placa”, únicamente en ciertas vías principales de alta congestión. Como resultado, las vías alternas y alimentadoras resultaron sumamente congestionadas. A la fecha, en Perú, el modelo es inviable y se ha dejado de usar; en Colombia, el modelo continúa en uso, ya que “pico y placa” les es necesario debido a obras de infraestructura programadas para el 2024 y que afectarán el tráfico en la capital colombiana.

La principal motivación del trabajo propuesto es la necesidad de contribuir con la optimización del tráfico vehicular mediante una gestión inteligente de semáforos. Manrique (2018) identifica que una de las causas principales del tráfico vehicular está relacionado con la gestión de semáforos pues presentan problemas específicos como: luces dañadas, visibilidad reducida para los vehículos y tiempos fijos asignados a los colores de semáforo. Un tiempo de fase inadecuado permite la ocurrencia de accidentes y tiempos de espera perdidos. En consecuencia, el tiempo del ciclo del semáforo representa una variable importante a considerar con el fin de mejorar la productividad y seguridad en las intersecciones viales (Araya-Porras et al., 2022).

En el Perú se ha observado que los semáforos con configuraciones de tiempos de fase fijos o predefinidos son los que más se han instalado. Los tiempos de luz verde son inadecuados. Tramos de la vía que están vacíos tienen luz verde; mientras tanto, hay carriles con vehículos esperando en rojo en la vía transversal. Al respecto, diversos estudios han abordado el tema de la asignación de tiempos de ciclo del semáforo, usando algoritmos que respondan a la realidad del entorno. Para ello, han recurrido a la Inteligencia Artificial (IA), para desarrollar teorías, algoritmos, métodos, tecnologías y sistemas de aplicación (Huawei Technologies Co., Ltd., 2023). Las técnicas más usadas son las de optimización, las de gestión de sensores y técnicas de aprendizaje automático (Tomar et al., 2022).

Este trabajo tiene como objetivo proponer un sistema inteligente de gestión de semáforos en tiempo real. Las principales contribuciones de este trabajo son la validación de los métodos de conteo vehicular basados en YOLOv4 en cuanto a niveles de precisión, la precisión de medición de velocidad vehicular basada en el Método de Detección de Intrusiones (IDM) y el aporte significativo del algoritmo heurístico, que en su conjunto forman el sistema inteligente, reduciendo el tiempo de espera de los vehículos en contraste con la configuración predefinida de los semáforos tradicionales. Los resultados encontrados servirán a otros investigadores para: 1) diseñar sistemas escalables y sincronizados para varias intersecciones viales bajo el enfoque de tiempo real y 2) crear componentes de software embebidos con el algoritmo heurístico para ser utilizados con transformadores o redes LSTM.

El presente artículo está estructurado en las siguientes partes: inicia con una revisión bibliográfica del tema, seguido por la descripción de los materiales y métodos aplicados. Luego, se describe la sección de resultados y discusión, donde se analizan los resultados obtenidos de la aplicación de algoritmos en términos de precisión. Finalmente, la sección de conclusiones y trabajos futuros.

2. Revisión bibliográfica

De los trabajos más recientes relacionados con el tráfico vehicular, un grupo está enfocado en la detección de carreteras, otro en la detección y seguimiento de vehículos, y otro grupo en los sistemas de transporte inteligente (ITS). Wang et al. (2019) sugieren que es posible monitorear secciones de carreteras para predecir el tráfico con técnicas como el modelado de datos y un modelo de predicción. Usaron una secuencia de matrices para entrenar un modelo profundo que combina una red neuronal convolucional (CNN) de aplicación específica para clasificación y segmentación de imágenes, según Jiménez-Murillo et al. (2023), y una red neuronal recurrente (RNN). Fundamentalmente, entrenaron un modelo profundo para predecir el flujo de tráfico y controlar las luces de tráfico con el fin de reducir la congestión.

Se han empleado técnicas de sustracción de fondo junto con métodos de análisis de contraste en distintas regiones de interés (ROI). Las métricas fueron: el número de vehículos en espera cuando un semáforo cambia de rojo a verde y la cantidad de vehículos que atraviesan la intersección, justo antes de que el semáforo pase de verde a rojo. El método se denomina Procesamiento de Textura de un conjunto de regiones de interés (Inglés-Romero et al., 2018).

Ashifuddin et al. (2019) desarrollaron un ITS con un enfoque de Internet de las cosas (IoT) para administrar la congestión del tráfico. Se utilizaron sensores estacionarios en la carretera para estimar y categorizar el nivel de congestión del tráfico en distintos tramos viales dentro de una ciudad, así como para analizar los datos de tráfico capturados como velocidad y densidad. Emplearon una red neuronal artificial (ANN) como base del sistema para clasificar los siguientes niveles de congestión: flujo libre, congestión media y congestión alta.

Actualmente, un sistema inteligente administrador de tráfico está conformado de componentes como: a) Adquisición de imágenes que, a través de sensores de

cámara, captura datos de la realidad, b) Extracción de características en función del reconocimiento, detección y seguimiento de vehículos y c) Aplicaciones de software de tráfico que suelen utilizar sistemas de posicionamiento global, sensores de tráfico y datos de tráfico en tiempo real. Tendencias actuales de ITS están basadas en metaheurísticas, lógica difusa, redes neuronales convolucionales, aprendizaje por refuerzo y una combinación de modelos y sistemas llamados híbridos (Nigam et al., 2023).

Para la adquisición de imágenes en tiempo real, el algoritmo que ha respondido de manera muy eficiente en procesos de detección es You Only Look Once (YOLO). A la fecha, es el estado de arte para la detección de objetos (Gonçalves et al., 2023). Los algoritmos previos a YOLO para la detección de objetos utilizan R-CNN o Fast R-CNN, procedimientos que son robustos y precisos, pero son procesos complejos, lentos y poco optimizables debido a que cada componente debe entrenarse por separado (Redmon et al., 2016). YOLO solo usa regresión con la red neuronal, debido a ello su rapidez. Zuraimi & Zaman (2021) evaluaron YOLOv4 en comparación con su versión previa en un sistema de detección de vehículos; según los resultados, se alcanzó una precisión del 82,08% en tiempo real de aproximadamente 14 fps en una tarjeta gráfica GTX 1660ti.

Respecto a la medición de la velocidad de objetos basada en video, se han encontrado estudios que utilizan métodos de sustracción del objeto en movimiento. Al objeto se considera como una mancha dentro de una elipse delimitadora, la cual se va ubicando en cuadros consecutivos a través de intervalos de tiempo (Cheung & Kamath, 2005). La técnica se ha mejorado con la técnica de estimación del fondo y seguimiento del movimiento mediante la segmentación del primer plano (Jeyabharathi & Dejeey, 2016).

Javadi et al. (2019) proponen el Método de Detección de Intrusiones (IDM), que es un método empleado para identificar cuando un objeto atraviesa una línea virtual y entra en una zona de interés entre puntos discretos. El intervalo entre los puntos discretos detectados corresponde al tiempo de muestreo de la cámara. Por consiguiente, la intrusión es detectada en una variación de distancia de detección $\Delta(m)$. Esta distancia de detección está directamente relacionada con el tiempo de muestreo de la cámara $t(s)$ y la velocidad hipotética del vehículo expresada como $v(m/s)$.

3. Materiales y métodos

La Figura 1 muestra la arquitectura del Sistema de Gestión de Semáforos (SGS) para intersecciones viales con giro a la izquierda. Las cámaras capturan el tráfico en la intersección. El componente de detección y seguimiento clasifica y cuenta los vehículos con el algoritmo YOLO y determina su velocidad usando un método de detección de intrusiones. Estos datos alimentan el algoritmo heurístico de asignación de tiempos de fase. Además, los datos se almacenan en un servidor Kafka para aplicaciones cliente en tiempo real.




Figura 1 – Arquitectura de componentes del Sistema de Gestión de Semáforos

3.1. Adquisición de imágenes

Respecto al proceso de adquisición de imágenes, es importante mencionar que en cumplimiento a la ley de protección de los datos en el Perú, el uso de las imágenes capturadas ha sido y será usado estrictamente en el contexto de la presente investigación. El detector de objetos no detecta la placa de vehículo; clasifica a una persona, pero no usa reconocimiento facial. Por tanto, la privacidad de los transeúntes, los vehículos y las edificaciones está garantizada. Esta fase se realizó en una intersección de alta congestión vehicular durante la hora pico (7 a.m. hasta las 8 a.m.), en período escolar y con giro a la izquierda permitido (Av. Pacífico - Av. Country en Nuevo Chimbote, Perú). Se ensambló un equipo tal como se ilustra en la Figura 2. Se utilizó un trípode de 6 m de largo, las cámaras de dispositivos móviles con resolución de 2 megapíxeles con aspecto 4:3 y un ángulo de inclinación θ del equipo 4 entre 30 y 60 grados, calibrados de acuerdo a la distancia del tramo y el pase peatonal. Se instaló el software Open Camera y TeamViewer en los equipos 4 y 5, para controlar y monitorear con el equipo 5 al equipo 4.




Figura 2 – Ensamblado de equipos para la adquisición de imágenes

De otra parte, antes de medir las velocidades de vehículos, se midió la longitud de las líneas discontinuas del tramo vehicular, seguido por la medición del espaciado de segmentos que es la distancia entre estas líneas, expresada en metros, ver Figura 3.



Figura 3 – Línea longitudinal y espaciado de segmentos de tramo

Se grabaron videos e imágenes para la comparación respectiva de los datos de la recolección manual con los datos que arrojen los métodos YOLO e IDM. Para los cálculos se consideró las medidas de línea longitudinal discontinua y espaciado de segmentos que son respectivamente de 3 m y 5 m para zonas urbanas de velocidad ≤ 60 km/h y de 4.5 m y 7.5 m para zonas de mayor velocidad (Ministerio de Transportes y Comunicaciones del Perú, 2018, p. 388).

3.2. Detección y seguimiento

Se utilizó un modelo preentrenado Yolov4 aplicado a una base de datos de 120 imágenes de intersección vehicular capturadas en la intersección descrita en la sección 3.1. No fue necesario proceder al etiquetado de imágenes con LabelImg porque, más que clasificación, el enfoque estuvo en detección. Se modificó el archivo yolov4.cfg, para solamente permitir detectar vehículos como camiones, bicicletas, automóviles, buses, motocicletas, entre otros, a fin de discriminar el conteo exclusivo de vehículos. Luego, para la parte experimental de conteo de las 120 imágenes de los tramos de la intersección vial, de manera aleatoria, con un intervalo de confianza de 95%, se consideró una muestra de 96 imágenes. En la Figura 4, se pueden observar tres escenarios de detección mediante algoritmo. En cuanto al proceso de seguimiento, se consideró de manera aleatoria simple 16 vehículos, durante un período de tiempo. Para llevar a cabo la medición manual de la velocidad, según el método IDM, se calculó el tiempo que un vehículo toma en recorrer una cierta distancia Δ (m), en este caso la distancia $d = 7.5$ m +2 m de tolerancia. Con un cronómetro digital se registró el momento en que el vehículo inició la intrusión de la distancia d hasta finalizar el recorrido d . El tiempo t en segundos obtenido de manera manual se emplea para determinar la velocidad en km/h mediante la siguiente fórmula: velocidad $v = (9.5 \text{ m}/t) \times (3600 \text{ s}/\text{h}) \times (\text{km}/1000 \text{ m})$.

3.3. Respecto al flujo de tráfico

El flujo de tráfico está determinado por la ecuación $Q = Vm \times D$, donde Q es el flujo de tráfico, Vm es la velocidad media y D es la densidad vehicular. Esto significa que Q varía

en función de los valores de V_m y D . En la Figura 5 se puede observar que si la densidad vehicular disminuye, la velocidad media crece y si la densidad vehicular aumenta, la velocidad media disminuye. Esto tiene su implicancia en la determinación empírica del tipo de congestión basada en la densidad.



Figura 4 – Detección y conteo de vehículos en tiempo real

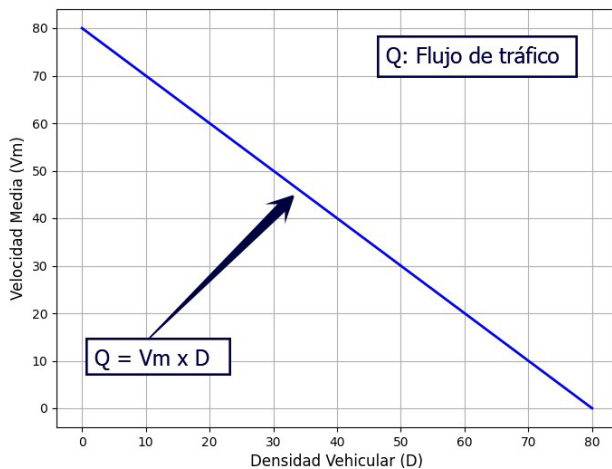


Figura 5 – Relación velocidad y densidad vehicular

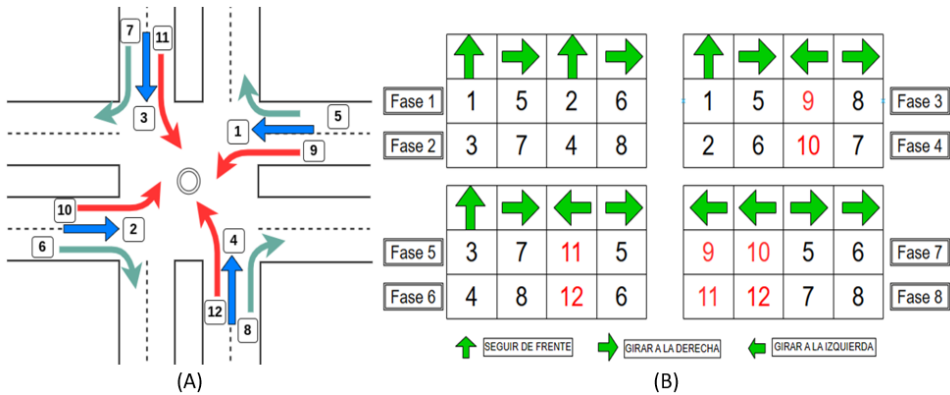


Figura 6 – Flujos conflictivos y no conflictivos en una intersección vial

En la Figura 6(A) se observa que, cuando entra en fase el par de flujos (1, 2), estos no presentarán conflictos entre sí. De manera similar sucede con el par de flujos (3, 4). El par de flujos (5, 6) y (7, 8) giran a la derecha tampoco presentan conflictos entre sí. Los flujos conflictivos son los flujos que giran a la izquierda como los pares de flujo (9, 2), (10, 1), (11, 4) y (12, 3). En la Figura 6(B) se observan 8 fases menos conflictivas conformadas por 4 flujos y se evidencia que cada vez que aparece un giro a la izquierda, la fase siempre presenta un flujo conflictivo que no afecta a los demás. Por ejemplo, en la fase 6 los flujos 4, 8 y 6 no entran en conflicto y el flujo conflictivo 12 tampoco los afecta. Por tanto, en un escenario en el que el tráfico entra en bloqueo mutuo, una de estas 8 posibilidades de fase podrá ayudar a descongestionar el tráfico.

3.4. Algoritmo para flujos no conflictivos (FNC)

La Tabla 1 muestra 3 tipos de modos: MODO 1 para condiciones de congestión de rutina, MODO 2 para congestión extrema y velocidad promedio cerca de cero (Prohibición de Giro a la Izquierda) y MODO 3, solo si resulta imposible que los flujos de tráfico lineales crucen la intersección de frente.

PAR	Par1	Par2	Par3	Par4	Par5	Par6	Par7	Par8
Flujos	(9,10)	(9,1)	(2,10)	(2,1)	(12,11)	(12,4)	(3,11)	(3,4)
MODO	3	1	1	2	3	1	1	2
PAR	NO	Par3	Par2	NO	NO	Par7	Par6	NO

Tabla 1 – Pares de flujos no conflictivos en una intersección vial

Algoritmo 1: Función FNC

1. Crear una estructura FNC [Flujo A, Flujo B, MODO, Par] donde contenga la matriz de la Fig.7:
2. Si MODO = 1 entonces, Avance de frente = True, Giro de Izquierda = True

Algoritmo 1: Función FNC

3. Si MODO = 2 entonces, Avance de frente = True, Giro de Izquierda = False
4. Si MODO = 3 entonces, Avance de frente = False, Giro de Izquierda = True

3.5. Algoritmo de inicio y configuración

En este algoritmo establece los datos de entrada específicos de cada tramo vehicular; como son el largo, ancho, número de carriles, espaciado entre vehículos y realiza los cálculos descritos en los ítems 4, 5, 6, 7 y 8 del algoritmo 2.

Algoritmo 2: Función Iniciar

1. Leer longitud (L), ancho (A) y número de carriles (Lane) de cada tramo.
2. Leer espacio longitudinal (EspaLong) y espacio lateral (EspaLate) entre vehículos.
3. Leer velocidad máxima (Vmax) y velocidad mínima (Vmin) permitida en el tramo.
4. Calcular el área de cada tramo (At) de intersección.

$$At[i] = longitud[i] \times ancho[i]$$
5. Calcular el área ocupada por vehículo (Av).

$$Av = EspaLong \times Espalate$$
6. Calcular el máximo número de vehículos por tramo (MaxVeh).

$$MaxVeh[i] = L[i] / EspaLong \times Lane[i]$$
7. Calcular la densidad máxima del tramo.

$$Dmax[i] = MaxVeh[i] / At[i]$$
8. Calcular el Tiempo máximo (Tmax) del tramo.

$$Tmax = L / Vmin$$

3.6. Algoritmo de operaciones con el número de vehículos y densidad

Este algoritmo calcula la Densidad de Grupo (dg) dividiendo el número de vehículos por el área del tramo. Luego, determina el Índice de Congestión de Tráfico (ICT), que es dg dividido por la densidad máxima del tramo, resultando en un valor en el rango de [0, 1]. Un ICT cercano a 0 indica baja congestión, mientras que cerca de 1 indica alta congestión.

Algoritmo 3: Operaciones con el número de vehículos y densidad

1. Obtener número de vehículos del tramo (numVeh)

$$numVeh[i] = procesosLecturaCamara(i) // \text{Aplica YOLO}$$
2. Calcular la densidad de grupo (dg)

$$dg[i] = numVeh[i] / At[i]$$
3. Calcular el índice de congestión de tráfico (ICT)

$$ICT[i] = dg[i] / Dmax[i]$$

3.7. Algoritmo de operaciones con la velocidad vehicular

Este algoritmo obtiene la suma de las velocidades de los automóviles en aplicación del método de seguimiento IDM. Por otra parte, si el número de vehículos del tramo es cero, entonces la velocidad media será cero; sino, la velocidad media del grupo será la suma de las velocidades del grupo dividido entre el número de vehículos del tramo. Luego, con la velocidad media del grupo (vmg) calculada, se tipifica el tipo de velocidad que puede ser baja, moderada, alta y muy alta.

Algoritmo 4: Operaciones con la velocidad vehicular

1. Obtener la suma de velocidades de los vehículos del grupo (svg)

$$\text{svg}[i] = \text{procesosVelocidadCamara}(i) // \text{Aplica IDM}$$
2. Calcular la velocidad media del grupo (vmg)

$$\text{Si numVeh}[i] = 0, \text{ entonces } \text{vmg}[i] = 0$$

$$\text{Sino } \text{vmg}[i] = \text{sumv}[i] / \text{numVeh}[i]$$
3. Establecer el tipo de velocidad media (tvm)

$$j=0$$

Mientras $j \leq 3$:

$$\text{Si } \text{vmg}[j] \geq 0 \text{ and } \text{vmg}[j] < 10, \text{ entonces}$$

$$\text{tvm}[j][0] = 1 \text{ y } \text{tvm}[j][1] = \text{“Vel. Baja”}$$

$$\text{Sino } \text{vmg}[j] \geq 10 \text{ and } \text{vmg}[j] < 30, \text{ entonces}$$

$$\text{tvm}[j][0] = 2 \text{ y } \text{tvm}[j][1] = \text{“Vel. Moderada”}$$

$$\text{Sino } \text{vmg}[j] \geq 30 \text{ and } \text{vmg}[j] < 50, \text{ entonces}$$

$$\text{tvm}[j][0] = 3 \text{ y } \text{tvm}[j][1] = \text{“Vel. Alta”}$$

$$\text{Sino } \text{tvm}[j][0] = 4, \text{ entonces}$$

$$\text{tvm}[j][1] = \text{“Vel. muy Alta”}$$

$$j += 1$$

fin-mientras

3.8. Algoritmo para establecer el tipo de congestión

Este algoritmo se encarga de verificar en qué rango se encuentra el ICT del tramo actual y así establecer el tiempo de fase al tipo de congestión. El tiempo de fase T_{fase} se determina con la ecuación $T_{fase} = L/vmg$, donde L es la longitud del tramo y vmg es la velocidad media del grupo. Lo cual indica que a menor velocidad media, mayor tiempo de fase y a mayor velocidad media, menor tiempo de fase. Considerando $L=100 \text{ m}$ y $Vmg=Vmin=7.2 \text{ km/h}$, según observación empírica, se ha obtenido la representación matemática que se muestra en la Ecuación 1, donde $f(x)$ es el tiempo asignado para cada tipo de congestión dado el factor x y el Índice de Congestión de Tráfico (ICT). Observar que, a medida que ICT crece, la función $f(x)$ incrementa su valor. $Tmax$ es obtenido del algoritmo 2.

$$f(x) = \begin{cases} T_{max} - 5(2x + 1) & \text{Si } x = 3 \wedge ICT \in [0, 0.25) \\ T_{max} - 5(2x + 1) & \text{Si } x = 2 \wedge ICT \in [0.25, 0.5) \\ T_{max} - 5(2x + 1) & \text{Si } x = 1 \wedge ICT \in [0.5, 0.75) \\ T_{max} - 5(2x + 1) & \text{Si } x = 0 \wedge ICT \in [0.75, 0.9) \\ T_{max} - 5(2x + 1) & \text{Si } x = -1 \wedge ICT \in [0.9, 1) \end{cases}$$

Se usó la estructura TC[Tipo-Congestión, descripción, T_{fase}].

Algoritmo 5: Tipo de congestión

$i=0$

Mientras $i \leq 3$

Si $ICT[i] >= 0$ and $ICT[i] < 0.25$, entonces

$x = 3$, $tc[i][0] = 1$, $tc[i][1] =$ "Congestión muy Bajo", $tc[i][2] = T_{max} - 5(2x + 1)$

Sino $ICT[i] >= 0.25$ and $ICT[i] < 0.5$, entonces

$x = 2$, $tc[i][0] = 2$, $tc[i][1] =$ "Congestión Bajo", $tc[i][2] = T_{max} - 5(2x + 1)$

Sino $ICT[i] >= 0.5$ and $ICT[i] < 0.75$, entonces

$x = 1$, $tc[i][0] = 3$, $tc[i][1] =$ "Congestión Medio", $tc[i][2] = T_{max} - 5(2x + 1)$

Sino $ICT[i] >= 0.75$ and $ICT[i] < 0.90$, entonces

$x = 0$, $tc[i][0] = 4$, $tc[i][1] =$ "Congestión Alto", $tc[i][2] = T_{max} - 5(2x + 1)$

Sino $x = -1$, $tc[i][0] = 5$, $tc[i][1] =$ "Congestión muy Alto", $tc[i][2] = T_{max} - 5(2x + 1)$

$i = i + 1$

fin-mientras

3.9. Algoritmo de gestión del semáforo

El algoritmo del semáforo constantemente está recibiendo información del entorno para ajustar la programación óptima de la fase del semáforo en el tramo actual. Siempre tiene en memoria la Fase Actual, el MODO, el ICT respectivo, el tipo de congestión tc , la velocidad media del grupo vmg y el tipo de velocidad media tvm . Además, monitoriza los tramos para determinar cuál tiene mayor ICT para asignar el tiempo de fase. Luego, dependiendo de la densidad y la velocidad media, realiza el reajuste automáticamente aumentando o disminuyendo el tiempo de la fase en segundos adicionales, según sea el caso. A continuación, inicia el conteo regresivo considerando los tiempos asignados y finalmente, efectúa el cambio de fase.

Algoritmo 6: Gestión del Semáforo

1. El sistema inicia su funcionamiento

FASE = 1

Mientras MODO = 1:

2- Monitorizar entorno

IndConTraf = IndiceCongestionTrafico() //ICT

Algoritmo 6: Gestión del Semáforo

```
TipoCon      = TipoCongestion() //tc
VelMedGr    = VelocidadMediaGrupo()//vmg
TipoVelMed   = TipoVelocidadMedia() //tvm
```

3- Monitorizar tramos

```
faseActual = FASE
Si faseActual == 1
    Si IndConTraf[0] > IndConTraf[1], entonces
        posMayorTraficFase = 0, tramo="Sur-Norte"
    Sino, posMayorTraficFase =1, tramo="Norte-Sur"
Si faseActual == 2
    Si IndConTraf[2] > IndConTraf[3], entonces
        posMayorTraficFase = 2, tramo="Este-Oeste"
    Sino, posMayorTraficFase = 3, tramo="Oeste-Este"
TipoTraf = TipoCon[posMayorTraficFase]
tinicio = time()
```

4. Reajuste: Incrementar tiempo de verde x Tipo de congestión

4.1- Si densidad es alta y velocidad promedio es muy baja, aumentar tiempo verde 3s

```
Si TipoCon[posMayorTraficFase][0] == 4 y TipoVelMed[posMayorTraficFase][0] == 1
    tiempoAdicional = 3
```

4.2- Si densidad es muy alta y velocidad promedio es muy baja, aumentar tiempo verde 5s

```
Sino TipoCon[posMayorTraficFase][0] == 5 y TipoVelMed[posMayorTraficFase][0] == 1
    tiempoAdicional = 5
```

4.3- Si densidad es muy baja y velocidad promedio es muy alta, reducir tiempo verde -5s

```
Sino TipoCon[posMayorTraficFase][0] == 1 y TipoVelMed[posMayorTraficFase][0] == 5
    tiempoAdicional = -5
```

4.4- Si densidad es baja y la velocidad promedio es muy alta, reducir el tiempo verde -5s

```
Sino TipoCon[posMayorTraficFase][0] == 2 y TipoVelMed[posMayorTraficFase][0] == 5:
    tiempoAdicional = -5
```

4.5- Se mantiene la duración de verde y no se agrega tiempoAdicional

```
Sino    tiempoAdicional = 0
```

5. Conteo regresivo

```
TiempoRegresivoVerde(TipoCon[posMayorTraficFase][2] + tiempoAdicional)
    tfinal = time()
    tiempoTranscurridoVerde(tfinal-tinicio)
    TiempoRegresivoAmarillo(3 segundos)
```

6. -Cambio de fase

```
Si FASE == 1, entonces FASE = 2
```

Algoritmo 6: Gestión del Semáforo

Sino FASE = 1

fin-mientras

3.10. Despliegue, producción y consumo

El sistema inteligente propuesto se basa en el modelo productor consumidor, ver Figura 7. El servidor central que ejecuta Linux Ubuntu 22.04 LTS, con memoria RAM de 8 GB, procesador Intel Core I7 1.9 GHz, GPU NVIDIA GeForce MX130, está formado por dos nodos principales. Un nodo que se encarga de la lógica de la Gestión del Semáforo y otro nodo Nodejs que se encarga de atender las peticiones web.

El artefacto SemáforoInteligente.py en Python 3.8 usa Yolo4 y OpenCV 4.8 para procesar datos del entorno, ejecutar un algoritmo heurístico, y enviar resultados al nodo semáforo. Este nodo muestra los tiempos de fase asignados y cuentas regresivas. ProductorKafka.py conecta y envía datos json a un servidor Kafka en la nube ConfluentKafka, incluyendo fecha, hora, tipo de tráfico, vehículos por tramo y tiempo de espera. El Servidor Kafka almacena datos en tiempo real en un tópico Intersección01 y maneja peticiones del programa ConsumidorKafka.js para la Aplicación Cliente.




Figura 7 – Diagrama de despliegue para el sistema en tiempo real

4. Resultados

En esta sección se presentan los resultados de la validación del modelo de sistema inteligente propuesto, incluyendo el conteo de vehículos, la medición de velocidad y los resultados del algoritmo heurístico. Para evaluar la precisión del contador de vehículos basado en detección de objetos frente al conteo manual, se usó la fórmula $precisión = (algoritmo/observador)$, donde algoritmo es el número de vehículos detectados y observador es el número de vehículos del conteo manual. Se realizaron 96 conteos, obteniendo una precisión media de 0.9127, una mediana de 1 y una varianza de 0.016, con un nivel de confianza del 95%. Según la prueba de normalidad de Kolmogorv a 96 grados de libertad (gl), se obtuvo un p-valor < 0.05. Por consiguiente, al aplicar la prueba no paramétrica de Wilcoxon para una muestra, se obtiene una significancia de 0.083, o sea p-valor ≥ 0.05 . Por tanto, se acepta que la mediana de *precisión* es de 0.95.

Respecto a la velocidad de los vehículos basada en el seguimiento de objetos mediante algoritmo, en contraste con la medición manual, se evaluó la variable *diferencia* expresada como $diferencia = |algoritmo - observador|$, donde *algoritmo* es la velocidad obtenida mediante algoritmo y *observador* es la medida manual de la velocidad. Para 16 conteos se obtuvieron los siguientes estadísticos descriptivos a un 95% de nivel de confianza: una diferencia media de 1.3633, una mediana de 1.35 y una varianza de 0.895. Según la prueba de normalidad de Shapiro-Wilk a 16 grados de libertad, se obtuvo una significancia de 0.521, o sea un p-valor ≥ 0.05 . Lo que implica que, en su conjunto, los datos de la variable *algoritmo* y *observador* respecto a velocidad de vehículos siguen una distribución normal. Además, se evaluó la variable *precisión* = $algoritmo/observador$ donde la prueba normalidad de Shapiro-Wilk indica una significancia de 0.540, es decir, p-valor ≥ 0.05 , y se acepta también que los datos de la variable *precisión* del algoritmo en determinar la velocidad de los vehículos siguen una distribución normal.

La prueba T de una muestra nos permitió comparar la media de la variable *precisión* con el valor de prueba esperado igual o superior a 0,95. Según los resultados que se observan en la Tabla 2, para los valores de prueba de 0.95, 0.98 y 0.99, el valor de prueba no se acepta debido a que el p-valor es menor a 0.05. Solo los valores de prueba de 0.96 y 0.97 se aceptan debido al p-valor ≥ 0.05 .

Por lo tanto, hay evidencia de que la variable *precisión* para la medición de velocidad de vehículos tiene una media aceptable en el rango de *precisión* entre el 96% y el 97%.

Variable	Prueba	t	gl	Sig. Bil.	Dif.medias	Inferior	Superior
PRECISIÓN	0,95	2.238	15	0.041	0.01307	0.0006	0.0255
PRECISIÓN	0,96	0.526	15	0.607	0.00307	-0.0094	0.0155
PRECISIÓN	0,97	-1.187	15	0.254	-0.00693	-0.0194	0.0055
PRECISIÓN	0,98	-2.899	15	0.011	-0.01693	-0.0294	-0.0045
PRECISIÓN	0,99	-4.611	15	0.000	-0.02693	-0.0394	-0.0145

Tabla 2 – Prueba T para una muestra, a un 95% de intervalo de confianza

Para la evaluación de los resultados del algoritmo de semáforo inteligente, se consideró 15000 escenarios simulados por el algoritmo (observar extracto de datos en la Tabla 3). Debido a que la variable de estudio *tiempo_espera_por_ciclo* es la suma del Tiempo de Espera (TE) de un tramo con el TE de su transversal. La ecuación $TEC_k = TE_{2k-1} + TE_{2k}$, donde $k=1,2,\dots, n/2$ expresa que se tomaron cada par de datos de tiempos de espera y se obtuvieron 7500 ciclos de semáforo.

Según la prueba de normalidad de Kolmogórov-Smirnov, el estadístico descriptivo presentó una media de 76.0661 s y una mediana de 76 s, con 7500 grados de libertad. Además, se obtuvo un p-valor < 0.05 . Con la prueba no paramétrica de Wilcoxon para una muestra, la mediana obtenida para la variable *tiempo_espera_por_ciclo* fue de 76 s con una significancia de 0.103, es decir, un p-valor ≥ 0.05 , lo cual nos permite retener la hipótesis de que la mediana es igual a 76 s a un nivel de confianza de 95%.

id	Fase	Tramo	V_NS	V_SN	V_EO	V_OE	TipoVel	Congestión	T.Espera
1	1	Norte-Sur	23	47	14	19	Alta	Medio	38
2	2	Oeste-Este	28	48	50	29	Moderada	muy Alto	58
3	1	Sur-Norte	43	25	26	27	Alta	Medio	38
...
14997	1	Sur-Norte	11	36	14	17	Alta	Bajo	28
14998	2	Oeste-Este	26	40	43	38	Moderada	muy Alto	58
14999	1	Sur-Norte	45	40	26	49	Baja	Medio	38
15000	2	Oeste-Este	15	23	12	40	Baja	Medio	63

Nota. V_NS, V_SN, V_EO, V_OE es el número de vehículos en cada tramo de norte-sur, sur-norte, este-oeste y oeste-este respectivamente, que a cierta tipo de velocidad Tipovel produce un tipo de congestión.

Tabla 3 – Extracto de la vista de datos de tráfico generado por simulación

En la Figura 8A se puede observar el gráfico de frecuencia, donde la mayor frecuencia de los tiempos de espera por ciclo se encuentran cercanos a 80 s y el valor de la media es igual a 76.0661 s. En contraste con el escenario real, donde el ciclo semafórico fijo es de 92 s, se hace notar la diferencia de 14 s. Por tanto, 76 s por cada ciclo semafórico significa 47.36 ciclos/h; mejora que se hace notar frente al número de ciclos semafóricos fijo igual a 39.13 ciclos/h.

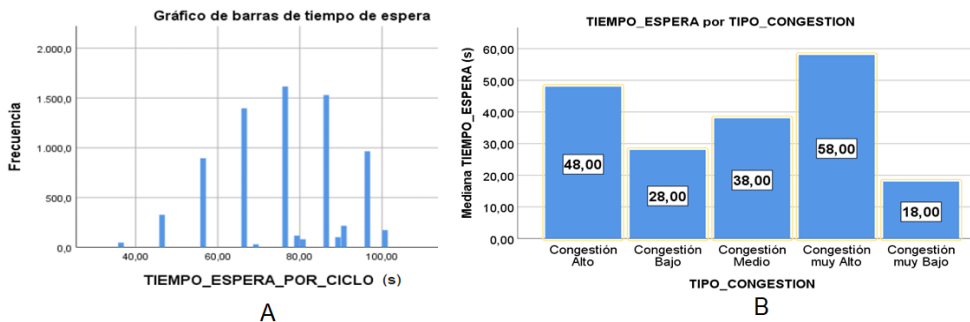


Figura 8 – Tiempo de espera y tipo de congestión

5. Discusión

Haber obtenido una precisión de 95% en cuanto al conteo de vehículos tiene una implicancia significativa en cuanto a confiabilidad del algoritmo de Yolov4, pues esto garantiza su funcionamiento e implementación en sistemas de producción. Sin embargo, los desafíos continúan respecto al problema del solapamiento u oclusión de vehículos, que son precisamente el causal del diferencial entre el conteo real y un conteo mediante

algoritmo. En la Figura 9 se observa un caso de oclusión donde el bus detectado ocluciona a otros vehículos que se encuentran detrás.



Figura 9 – Oclusión de vehículos

Los resultados del conteo de vehículos muestran que la precisión de un modelo de inteligencia artificial puede mejorarse, especialmente al abordar problemas de oclusión. La medición de velocidad alcanza una precisión entre 96% y 97% usando algoritmos de visión computacional, demostrando su viabilidad para aplicaciones en tiempo real. El presente trabajo destaca la importancia del tiempo real en el conteo y seguimiento de vehículos. Aunque YOLOv4 y el algoritmo IDM son precisos, mejorar la precisión podría aumentar la latencia y esfuerzo computacional.

El algoritmo 5 en este estudio añade dos tipificaciones de congestión: muy baja y muy alta, mejorando la segmentación del ICT en el rango (0;1). A diferencia de Ashifuddin et al. (2019), que consideran tres tipos de congestión (libre, media y alta), nuestra propuesta especifica cinco. Como muestra la Figura 8B, las congestiones muy alta y muy baja afectan significativamente el tiempo de espera por tramo vehicular y ciclo semafórico. Por otro lado, el algoritmo de gestión del semáforo ha reducido el tiempo de espera promedio por ciclo a 76 s, mejorando respecto al ciclo fijo de 93 s, usando un modelo heurístico basado en la velocidad y el número de vehículos. Aunque el FNC en Modo 2 o 3 no garantiza resultados alentadores, nuestro modelo supera al modelo de control difuso de Wang et al. (2022), quienes lograron una reducción del 14.59%, y el nuestro logró disminuir el tiempo de espera en un 18.3%.

En cuanto a la validez interna, la metodología utilizada para el conteo de vehículos y la medición de velocidad está claramente definida, asegurando que los datos recopilados son precisos y comparables bajo condiciones controladas. Respecto a la validez externa, la presentación de resultados cuantitativos y estadísticos descriptivos a un nivel de confianza del 95% y la reducción de tiempo de espera en un 18.3% nos permiten generalizar los resultados del algoritmo heurístico a una población más amplia y a otros tipos de escenarios. Sin embargo, también hay limitaciones potenciales, como considerar la precisión del método de detección de objetos en diferentes condiciones ambientales, festividades, accidentes y variables más difíciles de medir y controlar, como el comportamiento imprudente del peatón y/o del conductor en una intersección vial, que serían motivo de otro estudio.

Para una futura aplicación en zonas de alta densidad vehicular como Lima, Perú, se sugiere adoptar nuestro modelo propuesto, enfocándose en mejorar con algoritmos de sincronización entre intersecciones viales.

6. Conclusiones y trabajos futuros

Este trabajo propone un sistema inteligente heurístico para gestionar semáforos en intersecciones viales. Basado en el flujo vehicular, toma decisiones en tiempo real, optimizando el ciclo semafórico a 76 s y reduciendo el tiempo de espera en un 18.3% respecto a los ciclos fijos. Se validó una precisión del 95% con el algoritmo de conteo Yolo y del 96%-97% con el método IDM para medir velocidad, superando el 95% esperado. Futuras investigaciones podrían adaptar el algoritmo a redes LSTM o transformadores para mejorar el proceso del sistema heurístico actual.

Referencias

- Araya-Porras, E., Mora-Calderón, A., & Aguero-Valverde, J. (2022). Pedestrian crossing light violation in Costa Rica: exploring factors affecting mid-block crossing behavior. *Ingeniería*, 32(2), 115-134. <https://dx.doi.org/10.15517/ri.v32i2.50386>
- Ashifuddin, M., Rehena, M.. (2019). Intelligent Traffic Congestion Classification System using. *ACM Library*, 110-116. <https://doi.org/10.1145/3308560.3317053>
- Camargo, E. (2018). El “Pico y Placa” en Bogotá: ¿peor el remedio que la enfermedad? *Universidad Externado de Colombia*, 47. <https://doi.org/10.18601/01236458.n47.07>.
- Cheung, S., & Kamath, C. (2005). Robust background subtraction with foreground validation for urban traffic video. *Journal on Advances in Signal Processing*, 1-11.
- Gonçalves, M., Marques, T., Gaspar, P., Soares, V., & Caldeira, J. (2023). Prototype Solution for Detecting and Signaling Road Pavement Defects Based on Computer Vision Techniques. *RISTI - Revista Ibérica de Sistemas y Tecnologías de Información*, 25-44. <https://doi.org/10.17013/risti.52.25-44>
- Huawei Technologies Co., Ltd. (2023). *Artificial Intelligence*. Springer. <https://doi.org/10.1007/978-981-19-2879-6>
- Inglés-Romero, J., Cano-Baños, M., Doménech-Asens, G., & Morales-Estera, V. (2018). Traffic Metrics at Urban Intersections using a Low-Cost Image Processing Approach. *Association for Computing Machinery*, Article No. 9. <https://doi.org/10.1145/3243394.3243693>
- Javadi, S., Dahl, M., & Pettersson, M. (2019). Vehicle speed measurement model for video-based systems. *Computers & electrical engineering*, 76, 238-248.

- Jeyabharathi, D., & Dejeay, D. (2016). Vehicle Tracking and Speed Measurement system (VTSM) based on novel feature descriptor: Diagonal Hexadecimal Pattern (DHP). *Journal of Visual Communication and Image Representation*, 40, 816-830. Obtenido de <https://www.sciencedirect.com/science/article/abs/pii/S1047320316301705>
- Jiménez-Murillo, D., Henao-Garcés, S. A., Castro-Ospina, A. E., Duque-Muñoz, L., & Nieto-Mora, D. (2023). Segmentación de tejido cerebral mediante redes neuronales convolucionales basadas en U-Net. *RISTI - Revista Ibérica de Sistemas y Tecnologías de Información*, 5-24. <https://doi.org/10.17013/risti.52.5-24>
- Manrique, W. (2018). Estudio del tráfico y tendencias de movilidad urbana en Lima 2018. Lima: Marketwin. Obtenido de <http://willardmanrique.pe/wp-content/uploads/2018/09/Estudio-de-Trafico-y-Tendencias-de-Movilidad-Urbana-2018.pdf>
- Ministerio de Seguridad Pública de China. (2023). The number of motor vehicles in the country has reached 417 million, and the number of drivers exceeds 500 million. Obtenido de https://www.gov.cn/xinwen/2023-01/11/content_5736278.htm
- Ministerio de Transportes y Comunicaciones del Perú. (2018). Manual de dispositivos de control de tránsito automotor para calles y carreteras. Lima: MTC. Obtenido de https://portal.mtc.gob.pe/transportes/caminos/normas_carreteras/MTC%20NORMAS/ARCH_PDF/MAN_6%20DCT-2016.pdf
- Nigam, N., Singh, D., & Choudhary, J. (2023). A Review of Different Components of the Intelligent Traffic Management System (ITMS). *Symmetry*, 15(3), 583. <https://doi.org/10.3390/sym15030583>
- Nikas, A., Koasidis, K., Köberle, A., Kourtesi, G., & Doukas, H. (2022). A comparative study of biodiesel in Brazil and Argentina: An integrated systems of innovation perspective. *Renewable and Sustainable Energy Reviews*, 156, 112022. <https://doi.org/10.1016/j.rser.2021.112022>
- OCDE. (2011). OCDE. Obtenido de: <http://www.oecd.org/greengrowth/greening-energy/49157219.pdf>
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You Only Look Once: Unified, Real-Time Object Detection. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 779-788. Obtenido de https://www.cv-foundation.org/openaccess/content_cvpr_2016/papers/Redmon_You_Only_Look_CVPR_2016_paper.pdf
- Saus, M. (2023). State of the art about urban development and transport: reviewing tools for Latin America. *Economía, Sociedad y Territorio*, 991 - 1016. <https://doi.org/10.22136/est20231894>
- Tomar, I., Sreedevi, I., & Pandey, N. (2022). State-of-Art review of traffic light synchronization for intelligent vehicles: current status, challenges, and emerging trends. *Electronics*, 11(3), 465.

- Wang, M., Wu, X., Tian, H., Lin, J., He, M., & Ding, L. (2022). Efficiency and Reliability Analysis of Self-Adaptive Two-Stage Fuzzy Control System in Complex Traffic Environment. *Journal of Advanced Transportation*, 6007485. <https://doi.org/https://doi.org/10.1155/2022/6007485>
- Wang, S., Shen, Y., Bao, Z., & Qin, X. (2019). Intelligent Traffic Analytics: From Monitoring to Controlling. *Association for Computing Machinery*, 778-781.
- Zuraimi, M., & Zaman, F. (2021). Vehicle Detection and Tracking using YOLO and DeepSORT. *IEEE 11th IEEE Symposium on Computer Applications & Industrial Electronics (ISCAIE)*, 23-29. <https://doi.org/10.1109/ISCAIE51753.2021.9431784>

Sistema de Identificação de Expressões Faciais Básicas em um Editor de Texto Coletivo

André Gabriel Alves¹, Michele Alda Rosso Guizzo², Alexandra Lorandi³,
Patricia Alejandra Behar⁴

**gabriel.a1999@aluno.ifsc.edu.br; michele.guizzo@ifsc.edu.br; alexandra@ufrgs.br;
pbehar@terra.com.br.**

¹ Instituto Federal de Santa Catarina - Câmpus Criciúma, Santa Catarina, 88813-600, Criciúma, Brasil

² Instituto Federal de Santa Catarina - Câmpus Criciúma, Santa Catarina, 88813-600, Criciúma, Brasil

³ Universidade Federal do Rio Grande do Sul, Rio Grande do Sul, 90040-060, Porto Alegre, Brasil

⁴ Universidade Federal do Rio Grande do Sul, Rio Grande do Sul, 90040-060, Porto Alegre, Brasil

DOI: 10.17013/risti.54.88-103

Resumo: O estudo apresenta um sistema de reconhecimento de expressões faciais, para detecção de emoções básicas de estudantes, durante a produção textual. A funcionalidade foi desenvolvida e implementada no editor de textos coletivo denominado ETC, e utiliza técnicas de visão computacional. O sistema apresenta uma janela de detecção de expressões do usuário, e uma página de relatório com dados armazenados ao longo do tempo de edição de um documento. A pesquisa foi dividida em quatro etapas, são elas: fundamentação teórica; escolha de ferramentas e bibliotecas; desenvolvimento da funcionalidade e inclusão no editor de textos; testes com especialistas e análise dos resultados. O estudo concluiu que é possível coletar informações referentes a emoções básicas, por meio de sistemas de visão computacional. O objetivo é apoiar professores no processo de ensino e aprendizagem, a partir das observações dos aspectos afetivos durante a produção textual. Contudo, existem ainda distorções por fatores externos, que dificultam a captação adequada das imagens.

Palavras-chave: Reconhecimento de Expressões; Visão Computacional; Editor de Texto Coletivo.

Basic Facial Expression Identification System in a Collective Text Editor

Abstract: The study presents a facial expression recognition system for detecting basic emotions in students during text production. The functionality was developed and implemented in the collective text editor called ETC, and uses computer vision techniques. The system presents a window for detecting user expressions and a report page with data stored over the time a document was edited. The research was divided into four stages: theoretical basis; selection of tools and libraries;

development of the functionality and inclusion in the text editor; testing with experts and analysis of the results. The study concluded that it is possible to collect information regarding basic emotions through computer vision systems. The objective is to support teachers in the teaching and learning process, based on the observation of affective aspects during text production. However, there are still distortions due to external factors, which make it difficult to capture the images properly.

Keywords: Expression Recognition; Computer vision; Collective Text Editor.

1. Introdução

As expressões faciais, reflexos dos estados de ânimo, desempenham um papel crucial no processo de aprendizagem. Reconhecê-las implica diretamente no contexto educacional, pois refletem na forma como os alunos se apropriam e compreendem novas informações (Longui, 2011).

O estado de ânimo pode afetar a motivação, a participação e o desempenho dos estudantes. Reconhecê-lo, pode favorecer a adaptação de conteúdos e práticas pedagógicas, pelos docentes, aumentando as chances de engajamento dos alunos (Perassinoto, et al, 2013); (Fonseca, 2016). Logo, a personalização da educação depende da capacidade de rastrear e identificar o comportamento do aluno, de modo a orientar o processo de aprendizagem. Uma abordagem assim, considera as particularidades de cada aluno, como interesses, conhecimentos prévios e ritmo de aprendizagem, permitindo que o ensino seja adaptado às suas necessidades (Tomás, 2021).

Nesse contexto, as tecnologias digitais utilizadas como apoio as práticas pedagógicas, permitem ao estudante criar coisas novas, compartilhar suas experiências e aprender em qualquer lugar. A afetividade aliada a intencionalidade e o planejamento, pode construir com uma comunicação mais efetiva e acolhedora entre professores e alunos (Moran, 2021).

Um exemplo de tecnologia que pode auxiliar na personalização dos processos educacionais é a visão computacional. Por meio de algoritmos e técnicas de processamento de imagens, essa tecnologia permite que os sistemas coletem informações e compreendam o conteúdo visual de expressões e vídeos (Backes & Junior, 2019).

A visão computacional pode ser definida como uma área da inteligência artificial, que capacita os computadores a explicar e compreender o mundo visual, assim como os seres humanos. Suas aplicações são diversas e incluem o reconhecimento facial, diagnóstico de doenças e identificação e geolocalização automática de potenciais criadouros do mosquito e pragas em plantações, vigilância inteligente, identificação de defeitos em pavimentos asfálticos e veículos autônomos. Essa tecnologia demonstra um grande potencial para contribuir com avanços em diversas áreas (Barelli, 2018); (Gonçalves, et al, 2023); (Lima, et al, 2021).

Frente ao exposto, a presente pesquisa visa apresentar os resultados do desenvolvimento de uma ferramenta de reconhecimento de expressões básicas dos estudantes, por meio da visão computacional. A sua importância provém da consideração que as emoções

básicas, podem ser identificadas através do comportamento, da ativação corporal e da expressão facial, sendo elas: alegria, nojo, raiva, surpresa, tristeza e medo (Possebon, 2017). A funcionalidade foi implementada em um editor de texto coletivo assíncrono, denominado Editor de Texto Coletivo (ETC). O objetivo é coletar os dados sobre as expressões faciais dos estudantes durante a produção textual para apoiar práticas pedagógicas a fim de aumentar o engajamento dos alunos. Desse modo, o professor pode observar os aspectos afetivos relacionados ao estudante, durante a produção textual, e a partir destas informações construir estratégias personalizadas, que apoiem o processo de ensino e aprendizagem.

O presente artigo está dividido em: fundamentação teórica descrita na seção 2, seguida pela metodologia na seção 3, que aborda os métodos e ferramentas escolhidas para desenvolvimento da aplicação. A seção 4 apresenta os resultados e discussões obtidos da construção da ferramenta e, ao final, a apresentação das conclusões.

2. Fundamentação Teórica

Esta seção apresenta o ETC, ambiente no qual foi implementado o sistema de reconhecimento de expressões básicas. Além disso, aborda o estudo das microexpressões faciais, tema fundamental para o desenvolvimento da ferramenta, visto que é com base neste estudo que as principais bibliotecas de reconhecimento de expressão se baseiam.

2.1. Editor de Texto Coletivo

As tecnologias desenvolvidas no contexto educacional podem auxiliar os alunos em suas atividades didáticas, bem como desempenham um papel fundamental na geração de informações para docentes e tutores (Pereira, et al, 2019)

Nesse contexto, o Editor de Texto Coletivo (ETC) surge como uma ferramenta que favorece a colaboração e organização coletiva e interativa na estrutura do texto entre estudantes durante a produção textual (Behar, et al, 2004). O Editor é uma plataforma de livre acesso desenvolvida pelo Núcleo de Tecnologia Digital Aplicada à Educação (NUTED) e está disponível em: <http://nuted.edu.ufrgs.br/etc/>.

O ETC apresenta recursos como chat e fórum de discussão que permitem elaborações coletivas. Também apresenta a biblioteca virtual onde podem ser cadastrados livros, artigos e documentos acadêmicos para apoio à escrita. Em paralelo, o editor oferece ferramentas de acompanhamento da produção, permitindo aos usuários identificar oportunidades de melhoria. Dentre as disponíveis estão o RecETC (Recomendado de Conteúdos) para recomendação de artigos, imagens e vídeos selecionados a partir da mineração das palavras-chave do texto e a RedETC (Rede de Conceitos) que exibe um grafo relacionando os conceitos-chave do texto com a respectiva autoria dos termos. A Figura 1 apresenta a tela de edição de um texto no ETC.

Pelas características dos recursos e suas intencionalidades, destaca-se que o ETC tem maior importância e foco no desenvolvimento de pesquisas acadêmicas relacionadas às tecnologias aplicadas na educação.

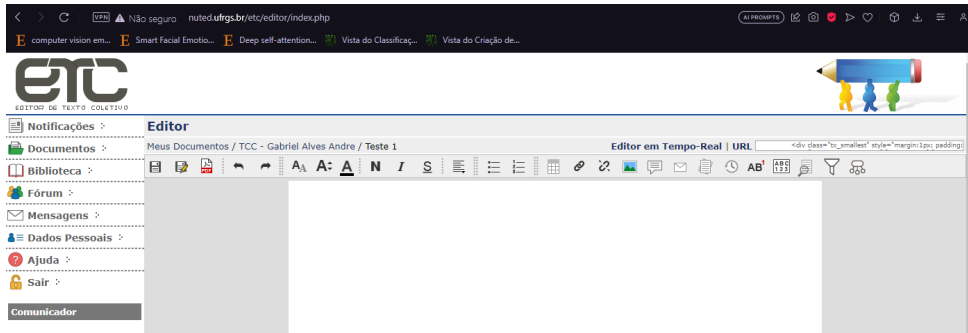


Figura 1 – Tela de edição de textos no ETC.

2.2. Estudo das Microexpressões Faciais

O estudo das microexpressões faciais ficou amplamente reconhecido após a publicação do livro “Facial Action Coding System: A Technique for the Measurement of Facial Movement” (FACS) em 1978, escrito pelo psicólogo Paul Ekman e o biógrafo Wallace Friesen. Neste trabalho, os pesquisadores identificaram as Action Units (AU), que são movimentos musculares faciais que envolvem a contração ou relaxamento visível de um, ou vários músculos da face humana. Essas AU’s são utilizadas para determinar a expressão facial de um indivíduo (Ekman & Friesen, 1978). Assim, Ekman e Friesen (1978) definiram 6 (seis) expressões básicas universais: alegria, nojo, raiva, surpresa, tristeza, e medo, presentes na Figura 2.




Figura 2 – Expressões básicas universais.

Essas expressões, segundo os autores, são universalmente reconhecidas por pessoas de diversas partes do mundo, mesmo sem palavras e independentemente das diferenças culturais. O motivo são as repetições de padrões de contração na musculatura da face ou as chamadas AU’s. Logo, para cada expressão, pode-se atribuir características universais:

- Alegria: há presença de um sorriso com estiramento dos lábios e os dentes expostos. Além disso, a distância entre a boca e o nariz diminui à medida que o sorriso se intensifica. As bochechas se elevam e os olhos podem apresentar um leve estreitamento, acompanhado de rugas ao redor deles.
- Nojo: durante essa expressão, o lábio superior se eleva expondo os dentes superiores e criando uma expressão de repulsa. Ao mesmo tempo, o nariz se enrugam, formando linhas verticais nasais. Essa combinação de elevação do lábio superior e enrugamento nasal é considerada uma característica distinta da expressão de nojo. Além disso, pode haver um ligeiro afastamento dos olhos e uma expressão facial geral de desconforto ou aversão.
- Raiva: as sobrancelhas são franzidas e puxadas para baixo formando uma linha reta ou inclinada. Os olhos podem se estreitar e fixar o alvo com um olhar intenso. A testa pode enrugar e a região em torno do nariz pode se contrair. Os lábios tendem a se pressionar firmemente e podem ficar tensos ou retos, sem curvatura ou sorriso. Pode haver também um aperto da mandíbula e tensão visível no rosto.
- Surpresa: as sobrancelhas se levantam rapidamente, formando uma curva arqueada. Os olhos se abrem amplamente com as pálpebras superiores elevadas e as sobrancelhas levantadas. A boca também se abre, muitas vezes com os lábios levemente separados. A testa pode enrugar momentaneamente devido ao levantamento repentino das sobrancelhas. Essa expressão facial de surpresa é caracterizada pela elevação das sobrancelhas, abertura dos olhos e abertura da boca, transmitindo a sensação de espanto ou choque.
- Tristeza: as sobrancelhas se abaixam, formando uma linha reta ou inclinada para baixo. Os cantos da boca se voltam para baixo, criando uma curva descendente nos lábios. Os olhos podem se encher de lágrimas ou ficar úmidos e pode haver um ligeiro afastamento das pálpebras superiores. Além disso, pode ocorrer uma leve contração dos músculos ao redor dos olhos, formando rugas.
- Medo: durante essa expressão as sobrancelhas se levantam e se juntam, formando linhas horizontais na testa. Os olhos se abrem amplamente com as pálpebras superiores levantadas e as sobrancelhas arqueadas. A boca também pode se abrir, com os lábios esticados e os cantos voltados para trás. Além disso, a pele ao redor dos olhos pode enrugar e a parte inferior do rosto pode se retrair ligeiramente.

Tais expressões são relevantes para o contexto dessa pesquisa, uma vez que se enquadram como uma importante ferramenta de análise de emoções, pois são responsáveis por afetar diretamente o processo cognitivo do aluno (Longui, 2011).

3. Metodologia

Para otimizar a execução desta pesquisa, a metodologia foi baseada em dois autores (Dresch, et al, 2020) e (Beck, 2000). O primeiro, tem por objetivo facilitar o embasamento teórico e escolha das tecnologias que serão utilizadas durante a criação da ferramenta. O segundo tem como principal proposta implementar o método *Expreme Programming* (XP), com ênfase no desenvolvimento iterativo e incremental, onde o processo é realizado

mediante interações curtas e em cada interação o software é desenvolvido, testado e entregue. A metodologia *Extreme Programming* (XP) foi desenvolvida por Kent Beck no final da década de 1990 e é uma abordagem ágil para o desenvolvimento de software.

A partir do exposto, dividiu-se a metodologia em quatro etapas: (i) desenvolvimento da base teórica, (ii) seleção das ferramentas e bibliotecas, (iii) desenvolvimento das funcionalidades e integração no Editor de Texto Coletivo (ETC), (iv) realização de testes com especialista e análise dos resultados.

Na etapa 1 desenvolveu-se a Revisão Sistemática de Literatura (RSL), para realizar uma busca aprofundada sobre conceitos do estudo. O método de RSL foi dividido em cinco principais itens: definição do tema central; estratégia de busca; critérios de seleção; avaliação da qualidade, relevância e síntese dos resultados; e apresentação dos estudos. Com base nessa investigação, foi possível escolher as ferramentas e bibliotecas utilizadas para o desenvolvimento da funcionalidade (etapa 2), tendo como critério principal a disponibilidade gratuita e a portabilidade com ambientes de Web.

Na etapa 3 foram previstas a construção da ferramenta e a sua incorporação no ETC. A funcionalidade tem como objetivo reconhecer as expressões faciais, segundo a teoria de Ekman e Wallace (1978), durante a produção textual no Editor de Texto Coletivo. Neste sentido, por meio da webcam, o algoritmo captura as imagens e as classifica durante uma unidade de tempo. Os dados coletados são armazenados e podem ser consultados por todos os autores na forma de um gráfico.

Depois disso, se iniciou a etapa de testes (4). O objetivo foi verificar se a ferramenta apresenta bons resultados em termos de desempenho, usabilidade e segurança. A etapa 4 contou com a participação de um especialista e os dados foram coletados por meio de um formulário eletrônico composto por perguntas objetivas e subjetivas.

4. Resultados e discussões

Nesta secção são apresentados e discutidos os resultados de cada etapa da pesquisa.

4.1. Desenvolvimento da base teórica

Esta secção apresenta os métodos e resultados encontrados na Revisão Sistemática de Literatura (RSL), com o propósito de encontrar e analisar as pesquisas recentes relacionadas aos aspectos afetivos que as API's (*Application Programming Interface*) utilizam para o reconhecimento de feições por meio da visão computacional.

A estruturação desta RSL foi dividida em cinco etapas, apresentadas a seguir (Dresch, et al, 2020).

1. Definição do tema central - Definiu-se a pergunta norteadora da pesquisa desenvolvida, sendo ela: “Quais aspectos afetivos que as principais API's utilizam? ”. Também é recomendado utilizar-se de perguntas adicionais para complementação da pesquisa e clareza no entendimento dos tópicos abordados. Desse modo, na sequência, encontram-se as perguntas também utilizadas como base nessa revisão bibliográfica: a) Quais são as classificações utilizadas pelas

- API's (Interface de Programação de Aplicação) na análise de feição do usuário?;
- b) Qual a linguagem de programação mais utilizada para reconhecimento facial?;
- c) Quais os pontos fracos e fortes de cada aplicação encontrada?
2. Estratégias de busca - Para a busca utilizaram-se sites de busca dos seguintes periódicos: Capes, IEEE, Scielo, Elsevier e Google Acadêmico. Além disso, foram consultadas as seguintes revistas de tecnologia: Renote, Revista Ibero-Americana de Educação e Revista Brasileira de Educação. As palavras-chave da pesquisa foram: “Visão computacional, API's e Aspectos Afetivos/Afetividade”. Assim, os termos de pesquisa utilizados foram: “visão computacional” E “reconhecimento de emoções” OU “computação afetiva”; “Computer vision” AND “Emotion Recognition” OR “affective computing”.
 3. Critérios de seleção - A pesquisa retornou aproximadamente 27 (vinte e sete) artigos. Contudo, depois da aplicação dos critérios de inclusão e exclusão, obteve-se como resultado de 7 (sete) artigos para análise. Os artigos analisados estão descritos na Tabela 1.

Autores	Expressões	Biblioteca	Banco de dados	Linguagem de programação	Considerações dos autores
Scardua et. al, 2019.	Alegria, tristeza, raiva, medo, repulsa (nojo) e surpresa (espanto)	Open CV	Não informado	Python	Procedimentos estéticos podem dificultar o reconhecimento.
Neto et. Al, 2019.	Alegria, tristeza, raiva, medo, repulsa (nojo) e surpresa (espanto), neutro	Open CV	Compound Facial Expressions of Emotion Database	Python	Maior acerto em emoções como: repulsa, felicidade e medo.
Behling, Alexandre. 2019.	Desgosto, Felicidade, Medo, Neutro, Raiva, Surpresa, Tédio, Tristeza	Open CV	Open Face	Python	Média de 66% de acerto nas emoções.
Ferreira, Michael. 2021.	Alegria, Nojo, Medo, Feliz, Triste, Surpresa, Neutro.	Open CV	FER2013	Python	Média de 60% de acerto nas emoções.
Aranha, Renan. 2022	Alegria, Nojo, Medo, Feliz, Triste, Surpresa, Neutro.	Face-API	Microsoft	JavaScript	Não faz considerações relevantes API.
Mendonça, Thomas. 2018.	Desgosto, Surpresa, Felicidade, Tristeza e Medo.	Open CV	JAFFE	Python	Média de 62% de acerto nas emoções.

Autores	Expressões	Biblioteca	Banco de dados	Linguagem de programação	Considerações dos autores
Guedes et. Al, 2022.	Alegria, Nojo, Medo, Feliz, Triste, Surpresa, Neutro.	Face-API	Microsoft	JavaScript	Acurácia entre 60% e 90%.

Tabela 1 – Síntese dos Resultados

4. Avaliação da qualidade, relevância e síntese dos resultados - Nesta etapa da revisão sistemática realizou-se o estudo dos artigos selecionados. A partir deles, foi possível encontrar informações relevantes para o presente estudo, considerando a plataforma de programação, os aspectos afetivos analisados, a ferramenta de análise utilizada para inferir as feições, o banco de dados ou *datasheet* e a linguagem de programação padrão utilizada para a aplicação. A partir dessa última etapa foram selecionadas as informações dos artigos estudados, como: expressões identificadas por cada autor, ferramenta de análise das expressões, plataforma padrão de desenvolvimento, banco de imagens ou modelos, linguagem de programação utilizada e os principais resultados obtidos por cada publicação. Os dados foram norteadores para as escolhas das ferramentas e procedimentos utilizados no desenvolvimento desta pesquisa.
5. Apresentação dos estudos - Com base nos estudos apresentados, pode-se observar diferentes técnicas e procedimentos utilizados para detecção de feições por visão computacional. Os artigos utilizados na pesquisa apresentaram resultados de acurácia e/ou considerações relevantes acerca da API e do banco de dados utilizado nos procedimentos que costumam variar de 60% a 90% de exatidão. As pesquisas demonstram que as API's apresentam acurácia semelhante e se faz necessário ficar atento a modificações faciais nos usuários. Apesar de cada biblioteca ter portabilidade para diferentes linguagens de programação, é mais comum que aplicações deste tipo sejam realizadas em Python e JavaScript.

4.2. Seleção das ferramentas e bibliotecas

Nesta pesquisa optou-se pelo uso da plataforma Visual Studio Code para desenvolvimento das atividades propostas. A escolha foi motivada por sua facilidade de implementação com ambiente Web e disponibilidade do banco de modelos da Face-API, além de ser gratuito e apresentar resultados satisfatórios nas pesquisas analisadas.

A Revisão Sistemática da Literatura também proporcionou o conhecimento das ferramentas de análise das expressões faciais. Assim, foi possível observar que as principais bibliotecas de identificação de expressões reconhecem as seguintes emoções: alegria, tristeza, raiva, medo, nojo, surpresa e neutralidade.

Nesta etapa, observou-se que diferentes bancos de imagens podem ser aplicados para realização desta tarefa, podendo utilizar modelos pré-treinados por inteligência artificial ou treinando um modelo próprio. Nesta pesquisa, optou-se por utilizar modelos já treinados devido a sua acurácia e por se tratar de uma aplicação com usuários e

cenários diferentes daqueles apresentados pelos estudos. Com base na análise, pode-se compreender, também, os cenários que dificultam a identificação da expressão facial, como: rostos com a presença de óculos, pelos faciais, tatuagens e procedimentos estéticos.

A escolha das ferramentas e bibliotecas utilizadas no desenvolvimento apoiou-se no levantamento de dados da Revisão Sistemática de Literatura. A partir dela, optou-se por escolher a biblioteca *FaceAPI*, disponibilizada pela *Microsoft Azure*. O motivo da escolha foram os bons resultados apresentados segundo as pesquisas, a gratuidade e a compatibilidade com ambientes de web.

É importante ressaltar que a biblioteca utilizada já apresenta funções de reconhecimento de expressões faciais e detecção facial treinados com modelos disponibilizados pela própria. Por conta disso, não se realizou o treinamento de uma ferramenta para o desenvolvimento dessa aplicação.

A plataforma de desenvolvimento utilizada foi a Visual Studio Code, desenvolvida pela Microsoft. A linguagem de programação escolhida foi JavaScript por permitir a manipulação da biblioteca *FaceAPI*, assim como a criação de gráficos que serão utilizados para a amostragem dos relatórios de expressões de cada aluno.

Para teste do servidor, utilizou-se a plataforma *Xampp*, ela permite que o usuário manipule e crie seu próprio servidor facilitando o processo de testes da aplicação.

Em relação ao desenvolvimento da funcionalidade e aplicação no Editor de Texto Coletivo, destaca-se que o código-fonte do ETC foi disponibilizado pela equipe do NUTED. Desse modo, a partir deste código, foi inserida a funcionalidade desenvolvida neste projeto.

4.3. Desenvolvimento das funcionalidades e integração no Editor de Texto Coletivo (ETC)

Nesta fase, utilizou-se a biblioteca *FaceAPI* em conjunto com a linguagem de programação JavaScript. Nesta biblioteca há a presença de um banco de modelos de faces e expressões disponibilizados gratuitamente pela Microsoft.

O algoritmo identifica e cria uma caixa delimitadora (*bound-box*) ao redor da face do usuário quando a webcam é acionada, retornando sua expressão em tempo real. O resultado numérico é apresentado em formato de porcentagem, sendo, basicamente, a correlação dos traços da expressão do usuário com as expressões do banco de modelos. Logo, o programa pode retornar mais de uma expressão, porém com valores diferentes de correlação. O resultado desse processo está na Figura 3.

Com base na Figura 3, pode-se observar que a biblioteca retorna dois tipos de valores. Na parte superior do retângulo em azul tem-se a probabilidade de existir uma face na *bound-box*. Além disso, o valor apresentado na cor branca na parte inferior do quadro, representa o resultado em percentual da emoção capturada naquele momento, em comparação com as expressões do banco.




Figura 3 – Retorno das expressões.

A ferramenta retorna sete tipos de expressões: alegria, nojo, raiva, surpresa, tristeza, medo e neutralidade (ausência das demais expressões). Assim, para implementar essa aplicação em uma página da web, foi necessário a integração desse algoritmo com outro programa na linguagem HTML, sendo este, responsável por definir a estrutura e formatação da tela do usuário. Além disso, foi desenvolvido um algoritmo para receber o código de identificação do texto e o nome do usuário.

A tela gerada por essa etapa é apresentada na Figura 4. Os dois botões funcionam respectivamente para: Gerar Relatório e Salvar Expressões. O primeiro tem a função de abrir uma página de relatório e o segundo tem a função de armazenar as informações no banco de dados manualmente.

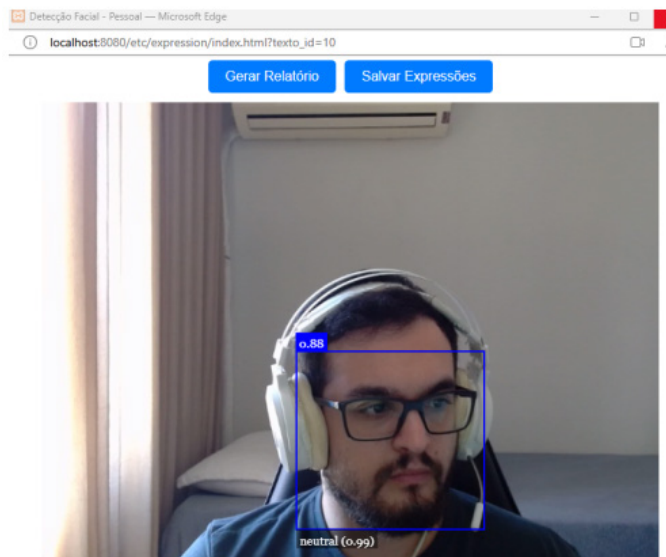


Figura 4 – Janela de detecção de expressões.

O armazenamento das informações geradas pela captação das expressões faciais do usuário é realizado a partir de uma matriz que contabiliza as ocorrências das expressões. O algoritmo atualiza a expressão com a maior correlação a cada segundo, incrementando o valor correspondente na matriz. Durante esta etapa, a expressão de “neutralidade” foi excluída devido à alta incidência durante a produção textual, prejudicando a análise do gráfico da Figura 5. Para a geração do relatório foi criada uma tabela no banco de dados do ETC usando MySQL. Ela armazena as expressões, um identificador de texto chamado de “Id_text”, o tempo total de escrita do usuário em milissegundos e o nome do usuário que está utilizando a plataforma.

O envio dessas informações ao banco de dados foi desenvolvido em JavaScript e utiliza o método assíncrono Ajax para se comunicar com um sub-programa implementado em PHP. Este último é responsável por receber as informações e encaminhá-las para o banco de dados por meio do servidor principal. O sistema grava os dados no banco quando: i) O usuário clica no botão “Salvar Expressões” na janela principal da aplicação (Figura 4); ii) O usuário pressiona o botão “Gerar Relatório” na janela principal da aplicação (Figura 4) ou iii) O usuário salva o documento de texto utilizando o botão disquete do ETC (Figura 1).

Desse modo, é possível assegurar que o usuário não perca suas informações durante o processo de escrita, uma vez que o ETC não salva automaticamente o documento. Além disso, para prevenir que o usuário encerre a aplicação sem salvar, foi desenvolvido um pop-up de alerta que notifica quando os dados não foram salvos antes do fechamento da janela.

A página de relatório de expressões pode ser observada na Figura 5. O código desta página combina as linguagens de programação HTML e JavaScript. Assim, os usuários conseguem visualizar informações detalhadas de todas as pessoas que contribuíram para a produção do texto.

Relatório de Expressões Faciais




Figura 5 – Página de relatórios de expressões.

A funcionalidade relatório conta com uma barra de seleção que permite ao usuário escolher o autor do texto que deseja analisar. Após realizar a seleção, deve-se pressionar o botão “Gerar Relatório”. Na tela é mostrado um gráfico em formato de rosca que apresenta a quantidade de ocorrências das expressões faciais. A biblioteca utilizada para criação do gráfico foi a “Charts.Js”, ela é livre e tem compatibilidade com o JavaScript. O respectivo número de expressões do gráfico surge na tela e é informado quando o usuário aproxima o cursor do mouse na região de interesse, assim como retrata a Figura 5.

Além do gráfico, nesta página também há a informação da quantidade de tempo que cada usuário contribuiu para a produção textual, essa informação ajuda os docentes na análise do engajamento do aluno.

A página visa garantir a melhor experiência e facilidade para o usuário. No gráfico há a presença de legendas relacionadas a cada expressão. As cores das expressões apresentadas no foram baseadas no modelo de representação dos estados de ânimo proposto pela pesquisadora Longhi (Longhi, 2011).

Essa página visa fornecer dados sobre as expressões dos alunos enquanto utilizam a ferramenta, destacando-as como a principal manifestação das emoções que, conseqüentemente, podem impactar no processo de aprendizagem (Longhi, 2011).

Um ícone foi incorporado à barra de ferramentas do ETC, conforme ilustrado em vermelho na Figura 6. Dessa forma, caso o usuário opte por não autorizar inicialmente a captura de dados de expressão facial, ele pode iniciar a aplicação em outro momento ou consultar os dados já armazenados sobre aquele documento. Além disso, se o usuário fechar a aplicação e desejar reabri-la, ele pode recorrer ao ícone da funcionalidade na barra de ferramentas da tela principal do ETC.



Figura 6 — Ícone de direcionamento para funcionalidades.

O ícone permite ao usuário abrir a página de relatório e a janela de captura de expressões expostas na Figura 4 e 5, respectivamente.

Além da implementação dos botões, foi criada uma mensagem de aviso, com propósito de assegurar que o autor do texto autorize a coleta de dados relacionados às expressões faciais. Assim, em situações em que essa autorização é concedida, o sistema procede com

a execução do programa principal, contudo, caso a autorização seja negada, a página não será aberta. Além disso, foram desenvolvidos dois cookies para o armazenamento de informações, cada um com funções específicas:

1. O primeiro cookie tem a finalidade de prevenir que duas janelas sejam abertas e executadas ao mesmo tempo, garantindo consistência nos dados armazenados no banco.
2. O segundo cookie assegura que o usuário confirme sua permissão de coleta de dados somente uma vez em um intervalo de 24 horas, promovendo controle adequado sobre a coleta de informações sensíveis.

4.4. Testes com especialista e análise dos resultados

Com a funcionalidade completa, foram conduzidos testes em colaboração com um especialista. O tempo de avaliação foi de 2 horas e, ao término do uso, aplicou-se um formulário para analisar os seguintes critérios: usabilidade, aspecto visual, tempo de resposta (desempenho), segurança, experiência durante o uso, ocorrências de erros e retorno (feedback) da ferramenta. A avaliação dos pontos ocorreu por meio dos seguintes métodos: atribuição de pontuações em uma faixa de valores de 1 a 5 (muito ruim, ruim, médio, bom e excelente) e questões dissertativas.

O especialista atribuiu os valores de pontuação 4 (bom) para os critérios de usabilidade, aspectos visual e experiência. Os critérios de tempo de resposta e segurança receberam a pontuação máxima (muito bom), e também relatou que não houve ocorrência de erros durante o uso da aplicação.

No entanto, relatou que houve confusão em relação ao processo de salvar as expressões, o que destaca a importância do botão “Salvar Expressões” da Figura 4. Por este motivo, antes de ser implementado em definitivo, esse ícone será retirado e a aplicação contará apenas com as opções de armazenamento automático das expressões (quando o usuário abrir a página de relatórios e ao salvar o texto).

Além disso, houve dúvida quanto ao processo de geração de relatório. Segundo o especialista, o botão “Gerar Relatório” da Figura 4, poderia ser descartado e essa funcionalidade ser implementada somente pelo ícone da Figura 6. Essa modificação será discutida e avaliada com o grupo de pesquisa.

A partir dos testes com um especialista, pode-se concluir que a funcionalidade atendeu aos requisitos necessários para garantir sua utilização. Além disso, com base nos testes, pode-se observar que existem pontos que podem ser modificados, de modo a garantir uma melhor experiência para o usuário.

5. Conclusões

Este artigo descreveu o desenvolvimento de uma funcionalidade integrada a um Editor de Texto Coletivo (ETC) que permite identificar, através da visão computacional, expressões de usuários durante o período de escrita. O objetivo é fornecer informações para análise dos aspectos emocionais dos usuários durante a produção textual.

Além disso, a pesquisa apresentou os resultados de uma Revisão Sistemática de Literatura, focada nas ferramentas já empregadas por outros pesquisadores, que desenvolveram pesquisas relacionadas a este estudo. A RSL, serviu de embasamento para a escolha da utilização da biblioteca *FaceAPI* e o desenvolvimento na plataforma Visual Studio Code através da linguagem de programação JavaScript.

A aplicação utiliza uma webcam para identificar o tempo de escrita e a ocorrência de seis diferentes expressões básicas (alegria, tristeza, raiva, medo, nojo e surpresa) no decorrer da produção textual do autor. Durante esse processo, alguns fatores podem interferir na exatidão das expressões, como: a presença de óculos, pelos faciais, tatuagens e procedimentos estéticos.

Os dados coletados podem ser analisados por meio de um relatório em que será possível identificar as emoções básicas dos alunos, com base nas suas expressões no decorrer do processo de escrita.

A funcionalidade desenvolvida desempenha um importante papel ao favorecer o aprimoramento do processo de aprendizagem, fornecendo informações sobre as emoções dos alunos durante a criação de um texto. Ao monitorar e analisar as expressões faciais e os estados emocionais dos estudantes, a ferramenta proporciona uma compreensão mais profunda sobre o engajamento e associado à atividade da criação textual. Essa abordagem não apenas pode enriquecer a avaliação do desempenho acadêmico, mas também permite ajustes pedagógicos mais personalizados, promovendo um ambiente de aprendizagem mais eficaz e adaptado às necessidades emocionais dos alunos.

Até o momento, a funcionalidade não foi integrada em definitivo no ETC, pois outras implementações foram incorporadas, o que poderia impactar no desenvolvimento de ambos os projetos. Portanto, optou-se por implementar e testar a ferramenta localmente, antes da sua publicação no servidor da UFRGS.

Dessa forma, o próximo passo da pesquisa será incorporar a funcionalidade no espaço de produção e iniciar sua aplicação em estudos de caso. Para isso, serão construídas estratégias pedagógicas que utilizem a ferramenta ETC em uma atividade de produção textual, em disciplinas do ensino superior. Desse modo, será possível analisar dados sobre a aplicação da funcionalidade com professores e alunos.

A ferramenta foi desenvolvida atendendo às demandas do Núcleo de Tecnologia Digital Aplicada à Educação (NUTED), equipe responsável pela criação do Editor de Texto Coletivo (ETC). Como sugestões para projetos futuros, tem-se a inserção de tecnologias de expressões faciais mais complexas como, por exemplo: confusão ou dúvida. Além de incluir a análise de fadiga dos escritores, permitindo aos professores e/ou tutores identificar o rendimento dos alunos com base nesses dados.

Referências

Aranha, R. V. (2022). Adaptação automática de jogos sérios a partir de emoções e traços de personalidade (Doctoral dissertation, Universidade de São Paulo). <https://doi.org/10.11606/T.3.2022.tde-31032023-080241>

- Backes, A. R., & Junior, J. J. D. M. S. (2019). *Introdução à visão computacional usando Matlab*. Alta Books Editora.
- Barelli, F. (2018). *Introdução à visão computacional: Uma abordagem prática com Python e OpenCV*. Editora Casa do Código.
- Beck, K. (2000). *Extreme programming explained: embrace change*. addison-wesley professional.
- Behar, P. A., Schneider, D., Colombo, M. C., & Bernardi, M. (2004). ETC: uma proposta de Editor de Texto Coletivo na web. In VII Congresso Iberoamericano De Informática Educativa–RIBIE. Actas, Monterrey.
- Behling, A. (2019). *Reconhecimento de Emoções em Vídeos Utilizando Redes Neurais Artificiais (Monografia, Especialização, Curso de Ciências da Computação, Universidade Federal de Santa Catarina)*.
- Dresch, A., Lacerda, D. P., & Junior, J. A. V. A. (2020). *Design science research: método de pesquisa para avanço da ciência e tecnologia*. Bookman Editora.
- Friesen, E., & Ekman, P. (1978). Facial action coding system: a technique for the measurement of facial movement. *Palo Alto*, 3(2), 5.
- Ferreira, M. H. S. (2021). *Reconhecimento facial para detecção de emoções utilizando redes neurais convolucionais com tensorflow*.
- Fonseca, V. D. (2016). Importância das emoções na aprendizagem: uma abordagem neuropsicopedagógica. *Revista Psicopedagogia*, 33(102), 365-384.
- Gonçalves, M., Marques, T., Gaspar, P. D., Soares, V. N., & Caldeira, J. M. (2023). Protótipo de Solução para Detetar e Sinalizar Defeitos em Pavimentos Rodoviários Baseado em Técnicas de Visão Computacional. *RISTI - Revista Ibérica de Sistemas e Tecnologias de Informação*, (52), 25-44. <http://dx.doi.org/10.17013/risti.52.25-44>
- Guedes, B. G., Xavier, D. U., Bezerra, R. C., & Simoni, V. M. (2022). API de reconhecimento de Action Units.
- Lima, G. A., Cotrin, R. O., Belan, P. A., & de Araújo, S. A. (2021). Sistema de visão computacional para identificação automática de potenciais focos do mosquito aedes aegypti usando drones. *RISTI - Revista Ibérica de Sistemas e Tecnologias de Informação*, (43), 93-109. <http://dx.doi.org/10.17013/risti.43.93-109>
- Longhi, M. (2011). *Mapeamento de aspectos afetivos em um ambiente virtual de aprendizagem*.
- Mendonça, T. D. B. (2018). *Sistema de reconhecimento de expressões faciais para classificação de emoções de usuários em sistemas computacionais*.
- Moran, J. (2021). *Metodologias ativas de bolso: como os alunos podem aprender de forma ativa, simplificada e profunda*. Arco 43.
- da Silva Neto, H., Canuto, C., Rampinelli, M., & Samatelo, J. (2018). Transfer learning for facial emotion recognition. In *Workshop de Visão Computacional* (pp. 190-195).

- Perassinoto, M. G. M., Boruchovitch, E., & Bzuneck, J. A. (2013). Estratégias de aprendizagem e motivação para aprender de alunos do Ensino Fundamental. *Avaliação psicológica*, 12(3), 351-359.
- Pereira, F. G. F., Rocha, D. J. L. D., Melo, G. A. A., Jaques, R. M. P. L., & Formiga, L. M. F. (2019). Construção e validação de aplicativo digital para ensino de instrumentação cirúrgica. *Cogitare enfermagem*, 24, 58334-58334. <http://dx.doi.org/10.5380/ce.v24i0.58334>
- Possebon, E. G. (2017). O universo das emoções: uma introdução. Libellus.
- Scardua, D. A., & Marques, K. (2018). Estudo da Identificação de Emoções Através da Inteligência Artificial.
- Tomás, C. (2021). Desafios éticos da Internet das Coisas: em torno da personalização na educação.

Prototipo de un sistema de seguimiento de boyas Lagrangianas para Oceanografía observacional

M. Carmen Clemente¹, Álvaro Hernández-Romero¹, Simone Sammartino¹,
Francisco Criado-Aldeanueva¹ y Pablo Otero¹

**mc.clemente@uma.es; alvarohernandezromero98@gmail.com; ssammartino@uma.es;
fcaldeanueva@ctima.uma.es; pablo.otero@uma.es**

¹ Instituto Universitario de Investigación de Ingeniería Oceánica de la Universidad de Málaga. Bulevar Louis Pasteur, 35. 29010 Málaga, España.

DOI: 10.17013/risti.54.104-120

Resumen: Este trabajo tiene como objetivo el desarrollo del prototipo de un sistema de posicionamiento que permita validar los modelos numéricos de predicción de aparición de residuos sólidos en las costas. Para ello, se ha realizado el diseño e implementación de un sistema de radiofrecuencia que permite el trazado de las trayectorias de boyas Lagrangianas. El sistema se compone de dos tipos de dispositivos: boyas de deriva superficial y receptores que permitan la extracción de los datos de las trayectorias de las boyas en tiempo real. Las boyas incorporan un receptor GNSS que registra su posición y se comunican con tecnología LoRa con un transceptor que se encuentre en su área de cobertura. Este sistema puede servir no sólo como herramienta de validación de modelos hidrodinámicos numéricos, también representa una metodología escalable, con amplio potencial de uso en el campo de la Oceanografía observacional.

Palabras-clave: boya Lagrangiana; residuos sólidos en costas; tecnología LoRa.

Prototype of a Lagrangian buoy tracking system for observational Oceanography

Abstract: The objective of this work is to develop a prototype of a positioning system to validate the numerical models for predicting the occurrence of solid waste on the coasts. For this purpose, the design and implementation of a radiofrequency system that allows the tracing of Lagrangian buoy trajectories has been carried out. The system is composed of two types of devices: surface drifting buoys and receivers that allow the extraction of data from the buoy trajectories in real time. The buoys incorporate a GNSS receiver that records their position and communicates with LoRa technology with a transceiver located in its coverage area. This system can serve not only as a validation tool for numerical hydrodynamic models, but also represents a scalable methodology with a wide potential for use in the field of observational Oceanography.

Keywords: Lagrangian buoy; solid waste on coasts; LoRa technology.

1. Introducción

La aparición de residuos sólidos en las costas representa hoy en día un desagradable problema para la mayoría de las ciudades costeras españolas y europeas, que se ven obligadas a invertir grandes sumas de dinero para paliar los efectos negativos que estos sucesos tienen en el turismo costero y en el bienestar social. La Unión Europea reconoce oficialmente a las llamadas comúnmente toallitas higiénicas como uno de los contaminantes de mayor impacto en su Decisión 2017/848/UE (UE, 2017), y define directivas para su eliminación. España identifica a las toallitas como uno de los puntos clave de su campaña de sensibilización y alerta sobre su uso correcto en el decálogo ciudadano contra las basuras marinas publicado en octubre del 2018 por el Ministerio para la Transición Ecológica (MITECO, 2018).

El trabajo que se presenta aquí se enmarca en un proyecto de investigación cuyo objetivo final es proporcionar una herramienta de predicción de los hallazgos de residuos sólidos en las playas y se presenta, como caso de estudio del proyecto, el ejemplo de las toallitas higiénicas halladas periódicamente en las playas urbanas de la ciudad de Málaga. El objetivo principal puede alcanzarse a través de dos objetivos secundarios que tienen naturalezas complementarias: la científica y la tecnológica. El primer objetivo pretende desarrollar un modelo numérico hidrodinámico que pueda predecir de forma verosímil la circulación de la zona objeto de estudio, apoyándose en condiciones de contorno procedentes de las predicciones oceánico-meteorológicas. El segundo objetivo contempla el desarrollo e implementación de un sistema electrónico de radiofrecuencia (que en lo sucesivo se denominará sistema de seguimiento) que sea una herramienta de validación in situ del modelo numérico previsto en la parte científica. El presente documento se centra exclusivamente en este segundo objetivo, aunque, obviamente, su requisito funcional está ligado al primer objetivo.

El sistema se compondrá de dos tipos de dispositivos: boyas de deriva superficial (boyas Lagrangianas) y receptores en embarcaciones de superficie que permitan la extracción en tiempo real de los datos de las trayectorias de las boyas. Las boyas incorporarán un receptor GNSS (en inglés, Global Navigation Satellite System) que registrará su posición y serán nodos de una red con capacidad de determinar su posición. Una vez implementado con éxito el sistema de seguimiento, éste se desplegará en condiciones ambientales controladas para poder verificar las trayectorias esperadas de los residuos sometidos a distintos forzamientos externos y contrastar así los resultados del modelo hidrodinámico. Este sistema de seguimiento puede servir no sólo como herramienta de validación de modelos numéricos. También representa una metodología escalable, con amplio potencial de uso en el campo de la Oceanografía observacional, ya que permite reconstruir las corrientes de deriva locales con una resolución espacial mucho mayor que cualquier modelo numérico.

A modo de introducción, se hará una presentación general del sistema electrónico de radiofrecuencia (sistema de seguimiento) y, a continuación, en las sucesivas subsecciones, se proporcionarán los detalles de sus elementos. Se ha comenzado diseñando un sistema de seguimiento de boyas Lagrangianas (Niiler et al., 1995; Martínez-Ledesma, 2011; García-Ladona et al., 2016), cuya finalidad es trazar la trayectoria de cada una de ellas mientras se encuentren dentro del alcance de un sistema con tecnología LoRa

de comunicaciones y reportar esas trayectorias a un ordenador central. El motivo de incorporar tecnología LoRa es doble: primero, para minimizar el riesgo de pérdida de datos por la avería o pérdida de una boya; segundo, para facilitar su localización en caso de perderse de la vista de la embarcación nodriza o porque se abandonen para el trazado de trayectorias durante varias horas.

El término largo alcance LoRa (del inglés Long-Range) trata de una tecnología de radiofrecuencia que permite comunicaciones de datos con bajo consumo eléctrico (SEMTECH, 1960). Esta tecnología se utiliza para instalaciones donde no se disponga de alimentación eléctrica o no se desee radiar más energía de la estrictamente necesaria, así como aplicaciones del tipo IoT (del inglés Internet of Things) en las que se transmiten pequeños volúmenes de información. En principio, la nomenclatura utilizada en la práctica describe LoRa como una tecnología basada en modulaciones de espectro ensanchado, mientras que LoRaWAN se utiliza para la arquitectura de sistema y el protocolo de comunicaciones. LoRaWAN está gestionado por LoRa Alliance (LoRa, 2024), que es una asociación abierta y sin ánimo de lucro, cuyo propósito es la promoción y la gestión de dicho estándar que se describe en la recomendación ITU-T Y.4480 de la Unión Internacional de Telecomunicaciones (ITU, 2021).

La tecnología de redes de área extensa de bajo consumo ya ofrece comunicación de largo alcance, lo que permite nuevos tipos de servicios (Tipán-Alcívar et al., 2022; González-Palacio et al., 2020). Existen varias soluciones (Goursaud & Gource, 2015), entre las que cabe destacar M2M (Machine-to-Machine) que tiene la ventaja de ser ofrecida por operadores de telefonía celular, lo cual abarata algunos costes, pero no está disponible en el mar cuando se sale del alcance de las estaciones costeras de los operadores, y redes de área extensa de baja potencia LPWAN (en inglés, Low Power Wide Area Network) que permiten transmitir datos entre un dispositivo y una estación base separados por centenares de metros o incluso algunos kilómetros con muy bajo consumo energético (Link Labs, 2016). LoRaWAN es sin duda la tecnología más adoptada de las LPWAN porque no depende de un operador y está madura, encontrándose en el mercado soluciones LoRa de coste muy asequible. La tecnología LoRa dispone de un nivel físico de bajo consumo eléctrico que nominalmente consigue alcances de alrededor de 2 km en zonas urbanas y mayores en zonas con menor presencia humana. En transmisión, su principal inconveniente es el pequeño régimen binario (entre 0,3 y 27 kb/s). Régimen binario y alcance son parámetros interrelacionados; si aumenta uno, disminuye el otro (Adelantado et al., 2017).

2. Arquitectura del sistema de seguimiento

El sistema desarrollado consiste en un conjunto de boyas equipadas con dispositivos electrónicos y un equipo colector de la información de posición que envía cada boya. En la Figura 1 se muestra la configuración del sistema mediante un esquema de bloques. Funcionalmente, el sistema consta de un subsistema de cálculo de la posición de las boyas, un subsistema de comunicaciones y un subsistema de presentación y almacenamiento. Estas funciones están repartidas entre los distintos elementos del sistema. En lo que se refiere a denominación, se usa como referencia el subsistema de comunicaciones y en lo sucesivo se llamará nodo a los elementos que se alojan en cada una de las

ubicaciones, que pueden ser las boyas de deriva en lo relativo a la determinación de la posición y la transmisión de ésta hacia el subsistema de presentación y almacenamiento y también este último subsistema. Se dirá “nodo transmisor” para referirse a la unidad funcional alojada en una boya y “nodo receptor” a la unidad funcional del subsistema de presentación y almacenamiento.

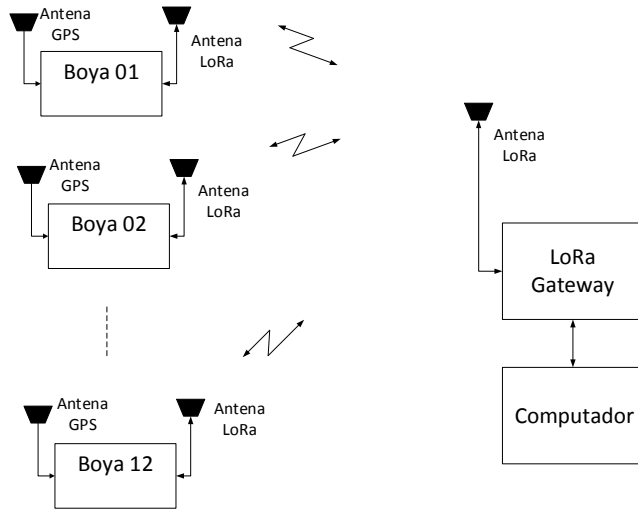


Figura 1 – Esquema de bloques del sistema propuesto.

Un Gateway (en español podría traducirse como “pasarela”) es un dispositivo electrónico que forma parte de una red de comunicaciones cuya misión es interconectar otros dispositivos de red para compartir recursos entre dos o más ordenadores. Se trata normalmente un equipo informático configurado para dotar a las máquinas de una red de área local LAN (en inglés Local Area Network) conectadas a él de un acceso hacia una red exterior, muy frecuentemente Internet. En el caso presente, el Gateway se usará como concentrador de los datos de la red LoRaWAN. El sistema desarrollado puede realizar el seguimiento de hasta ocho boyas. Esta cifra viene determinada por dos circunstancias: la primera es la capacidad, en bit/s, del enlace LoRa junto con la longitud del mensaje que envían las boyas al Gateway; y la segunda es el alcance nominal del enlace LoRa, que no cubra el área donde se han desplegado las boyas.

Los dispositivos electrónicos de cada una de las boyas se muestran en la Figura 2. Estos dispositivos a bordo de las boyas, o nodos transmisores, incorporan un módulo receptor GPS (en inglés, Global Positioning System) del cual leen la posición de la boya en la que están instalados, almacenan esa posición y el instante de lectura en la memoria interna del dispositivo y lo envían a través de un enlace LoRa a un Gateway que se encuentra en un buque de superficie. En la Figura 1 y en la Figura 2 se muestra, de forma esquemática, que los nodos transmisores y receptores están equipados con esos módulos de comunicaciones, lo que se ha reflejado con los símbolos de las respectivas antenas.

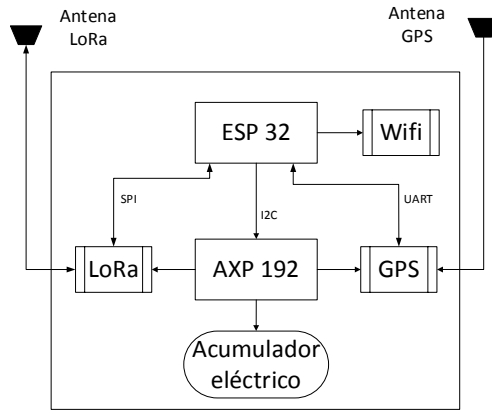


Figura 2 – Esquema de bloques de los dispositivos electrónicos que incorpora cada boya.

En la Figura 2 se muestra el esquema de bloques del nodo transmisor que se describen sólo desde el punto de vista funcional. El elemento principal es un microcontrolador de bajo consumo (ESP32 en la figura). Este microcontrolador usa distintos tipos de buses para comunicarse con los otros módulos. Los que se usan en la aplicación en cuestión son: el módulo GPS conectado por un bus serie UART (en inglés, Universal Asynchronous Receiver-Transmitter), que es encargado de obtener la posición del nodo del sistema; el módulo LoRa conectado por un bus serie síncrono SPI (en inglés, Serial Peripheral Interface), que constituye el nivel físico de la red LoRaWAN y el controlador de la alimentación eléctrica (AXP 192) conectado a través de un bus I2C (en inglés, Inter-Integrated Circuit). Este controlador sirve, entre otras cosas, para gestionar la carga de un acumulador eléctrico (coloquialmente batería) de reserva por si cae la alimentación externa. En la presente aplicación se opera en sentido inverso, es decir, el acumulador es la fuente principal de alimentación del nodo. Más adelante, se describe el tipo de acumulador que se utiliza en este prototipo.

2.1. Requisito funcional

El objetivo de esta parte del proyecto es el diseño y la construcción de un conjunto de elementos que permitan adquirir, monitorizar y almacenar en memoria la velocidad vectorial de la corriente superficial en el mar. En la medida de lo posible, se diseñará un sistema que cumpla los estándares WOCE (en inglés, World Ocean Circulation Experiment) (Lumpkin et al., 2017; Richardson, 2001; Sybrandy & Niiler, 1991).

El requisito funcional del sistema de seguimiento se articula en los siguientes puntos:

- La boya debe tener una autonomía eléctrica de 24 h y no constituir un peligro para la navegación.
- La boya debe almacenar su trayectoria (instante y posición) al menos una vez por minuto) durante, al menos, 24 horas.
- La boya debe enviar el dato de su posición en tiempo real por un enlace usando el protocolo LoRaWAN, al menos una vez por minuto. Si la boya detecta que no

está dentro del alcance de un receptor, no transmitirá sus datos de posición. Si recupera el enlace, debe continuar con la transmisión.

- El desplazamiento de las boyas debe ser debido principalmente a la deriva y no al abatimiento por viento. Para ello, se busca que el cociente entre las superficies de la obra viva y de la obra muerta de las boyas llegue a ser 40, sin por ello constituir un peligro para las personas, ni para la navegación o el medio ambiente.
- El sistema permitirá almacenar individualmente la trayectoria de distintas boyas, al menos ocho de ellas (en la Figura 1 se muestran hasta 12, pero por motivos ya indicados, se ha considerado que ocho es un número satisfactorio).
- La boya será fácilmente desplegable y su continente contará con la forma adecuada para poder ser recuperada y subida a bordo de una embarcación con ayuda de un bichero.

2.2. Esquema de funcionamiento del sistema de posicionamiento

La Figura 3 muestra el esquema de funcionamiento del sistema de posicionamiento, donde están clasificados los requisitos funcionales del sistema. La Tabla 1 muestra la clasificación detallada, así como la prioridad y la precedencia de los distintos requisitos. Una descripción somera de estos requisitos se detalla a continuación:

- R1.1 Identificación: Los nodos transmisores se auto-numeran para determinar una identificación propia de cada nodo, con el fin de que el procesador central separe los distintos mensajes y trace la trayectoria de cada boya.
- R1.2 Leer GPS: Los nodos transmisores se comunican con el módulo GPS de la placa del microcontrolador para leer los datos que le entrega.
- R1.3 Procesar datos: De la trama que entrega el módulo GPS se extraen los datos de interés y se procesan. Los datos que se extraen son Latitud, Longitud, Hora, Fecha, Incertidumbre.
- R1.4 Formato de datos: Los datos de identificación de la boya, coordenadas geométricas e instante de tiempo se combinan con un formato determinado. Ese formato es: El formato de la trama de comunicación entre nodo transmisor y el receptor debe ser: id, ddmmyy (fecha), hhmmss (tiempo), Latitud, N/S, Longitud, W/E, Incertidumbre.
- R1.5 Almacenar datos: El microcontrolador almacena los datos formateados en R1.4 en la memoria interna del nodo al menos una vez por minuto.
- R1.6 Enviar datos: Los datos formateados también se envían al nodo receptor, dotado de un Gateway LoRa, al menos una vez por minutos.
- R2.1 Mostrar datos: El nodo receptor dispondrá de una interfaz donde se muestren los datos recibidos de los nodos transmisores. Esta interfaz puede ser la pantalla de un ordenador de tipo PC.
- R2.2 Salvar datos: El nodo receptor almacenará los datos recibidos en su memoria interna.

R2.3 Identificación de datos: El nodo receptor separará los datos de cada una de las boyas.

R3 Transferencia de ficheros: Los ficheros almacenados en el nodo receptor deben ser transferibles a un ordenador de tipo PC. Habrá un fichero por boya.

R4 Extracción de Datos: Independientemente de su transmisión por el enlace LoRa, los datos almacenados en cada nodo transmisor podrán ser extraídos de la boya una vez recuperada ésta.

R5 Autonomía: La autonomía del nodo transmisor debe ser de al menos 24 horas.

R6 Uso de LoRa: Las comunicaciones entre el nodo receptor y los nodos transmisores utilizarán tecnología LoRa.

La Tabla 1 muestra la clasificación detallada, así como la prioridad y la precedencia de los distintos requisitos.

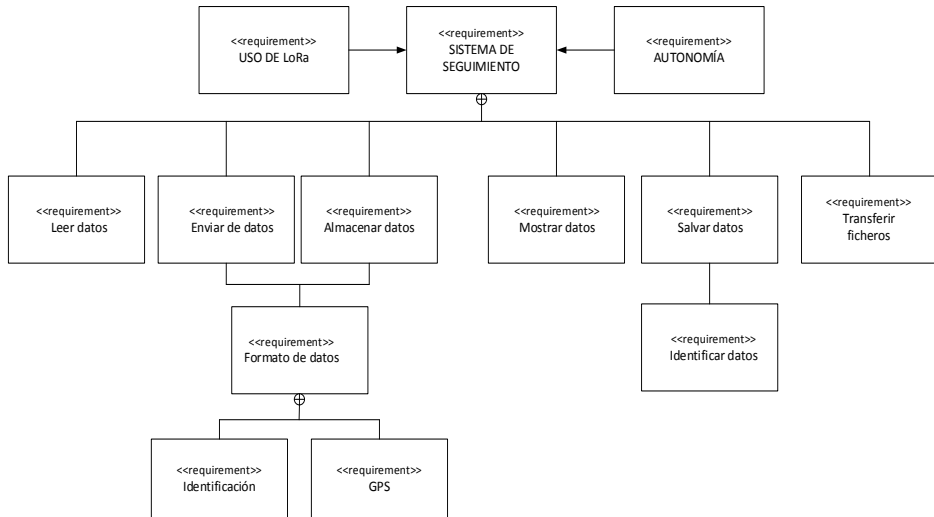


Figura 3 – Esquema de funcionamiento del sistema de posicionamiento.

ID	Nombre	Prioridad	Precedencia
R 1.1.	Identificación	1	
R1.2	Leer GPS	1	
R1.3	Procesar datos	1	R1.2
R1.4	Formato datos	1	R1.3, R1.1
R1.5	Almacenar datos	2	R1.4
R1.6	Enviar datos	1	R1.4
R2.1	Mostrar datos	2	R1.6

ID	Nombre	Prioridad	Precedencia
R2.2	Salvar datos	1	R1.6
R2.3	Identificar datos	1	R1.6, R1.1
R3	Transferir ficheros	1	R2.2
R4	Extraer datos	1	R1.5
R5	Autonomía	2	

Tabla 1 – Prioridad y precedencia de los requisitos funcionales (1 es la mayor prioridad).

3. Prototipo del nodo transmisor

El nodo transmisor es el conjunto de elementos que se alojan en cada una de las boyas de deriva. Se han construido cuatro prototipos del nodo transmisor, que se han montado en unas pseudo boyas basadas en una maleta estanca. Por tratarse de boyas de superficie, que no se espera que pasen en el agua más de 24 horas, no se ha considerado necesario hacer un diseño específico, lo que habría encarecido y retrasado su fabricación. No obstante, las maletas tienen la certificación de clase de protección IP67, y la integración de los componentes y las antenas se ha realizado garantizando el mismo estándar. Esto asegura que la boya pueda soportar las adversas condiciones ambientales del ambiente marino a las que se enfrenta. El principal elemento del nodo receptor, el cual aparece como ESP32 en el esquema de bloques de la Figura 2, es el sistema microcontrolador que se muestra en la Figura 4. Se trata del sistema LILYGO TTGO TBeam v1.0 (LILYGO, 2024) que está basado en el microcontrolador ESPRESSIF ESP32 e incorpora, además de ese circuito integrado y la memoria interna, un GPS Neo-6 y un módulo LoRa SX1278 de Semtech (Módem LoRa SX1278, 2024).

El sistema microcontrolador se alimenta mediante un acumulador eléctrico que se instala en el soporte que puede observarse en la imagen izquierda de la Figura 4. Se trata de un acumulador recargable Samsung 18650 de ion-Litio, 3,7V, 2,6 A·h, de terminal plano, con lo que se obtiene la autonomía requerida de 24 h.

Se ha diseñado y construido un pequeño mástil cuya finalidad es ubicar las dos antenas del nodo, para alejarlas del agua y separarlas una de otra y que, al mismo tiempo, ofrezca una resistencia al viento lo menor posible y no comprometa la estabilidad de la boya. El conjunto se muestra en la fotografía de la Figura 5, donde se observa a la izquierda la antena GPS, que es una antena activa CTI AEB-275 con ganancia nominal de 28 dB. A su derecha, en la fotografía, se observa la antena LoRa de uso común. En Europa, LoRa opera en las frecuencias de 863–870/873 MHz, mientras que GPS usa las frecuencias de 1575,42 MHz y 1227,6 MHz, por lo que la separación espectral consigue la no interferencia de ambas operaciones.

La boya que aloje la electrónica de los nodos transmisores debe ser una boya Lagrangiana, es decir, que se mueva por deriva, no por abatimiento. Obviamente, ese objetivo no se cumplirá completamente, ya que parte del costado de la boya quedará por encima de la línea de flotación (obra muerta). Para que el abatimiento sea mucho menor que la deriva se han tomado las siguientes medidas:




Figura 4 – Sistema microcontrolador usado en el nodo transmisor.



Figura 5 – Conjunto de pseudo boya y pequeño mástil que soporta las antenas GPS (izquierda) y LoRa (derecha).

- Se lastra la boya con grava y mortero para que al menos el 90% de su costado quede por debajo de la línea de flotación.
- Se dota a la boya de una vela submarina. Es una práctica común en boyas de deriva (Martínez, 2011). Esa vela es un cilindro circular de 4 m de generatriz y circunferencia directriz de 0,6 m de diámetro. Para fabricarla, se cosen juntos los dos lados largos de una lona de vela rectangular de 4 m x 1,9 m. Para

mantener la forma cilíndrica se usan cuatro sables de 1,8 m x 0,05 m x 0,002 m que se insertan en unos bolsillos cosidos horizontalmente a la vela, dos en ambos extremos del cilindro y otros dos separados 1,3 m de los anteriores. Y finalmente se lastra con cuatro plomos de submarinista de 0,5 kg cada uno, que se insertan en unos bolsillos cosidos justo encima del sable inferior.

3.1. Software del nodo transmisor

La programación de los nodos transmisores se ha realizado en lenguaje C, utilizando el entorno de desarrollo integrado (IDE, del inglés Integrated Development Environment) Visual Code. Durante dicho desarrollo fue necesario buscar librerías específicas para poder utilizar el módulo LoRa (GitHub, 2024 esp32) y poder encender los módulos LoRa y GPS haciendo uso del controlador eléctrico AXP192 (GitHub, 2024 axp192), ya que, todas las librerías y ejemplos para el dispositivo LILYGO se encuentran disponibles para el entorno Arduino.

En la Figura 6 se muestra el diagrama de flujo del software del nodo transmisor. Tras el encendido y la inicialización propia del microcontrolador, el nodo procede a determinar su identificador, que es el código que se utiliza en el nodo receptor para separar las distintas trayectorias de los nodos transmisores. A continuación, el microcontrolador establece la conexión con el módulo GPS, lo configura, que es proporcionarle los parámetros que deciden el tipo de trama y la tasa de refresco, principalmente, y procede a extraer los datos de posición de la trama que recibe. Luego empaqueta los datos que necesita transmitir con el formato propietario que se ha elegido, que es el descrito en R1.4 de la Subsección §2.2. Por último, los almacena en memoria y los transmite a través del enlace LoRa al Gateway. Tras la inicialización de los módulos periféricos del microcontrolador, las demás tareas las realiza en bucle cerrado, una vez por minuto. Si el nodo transmisor no hubiese estado dentro del alcance del enlace LoRa, todo o parte del tiempo en que ha estado operativo, cuando se recupera la boya es posible conectar el nodo mediante un puerto serie de tipo USB (en inglés, Universal Serial Bus) a un ordenador y extraer la trayectoria de la boya de la memoria interna del nodo.

Ahora pasamos a los casos de pruebas diseñados para verificar el correcto funcionamiento del nodo transmisor desarrollado en el proyecto, con el fin de validar la aplicación y comprobar que se cumplen todas las especificaciones enumeradas en el apartado de requisitos. Para realizar las pruebas relativas se han utilizado los dispositivos y circuitos junto con la programación, mencionados en los apartados anteriores. Estas pruebas están referidas a la lectura de GPS, el envío y almacenamiento de tramas de información, así como la autonomía de los nodos. Para alguna prueba es necesario conectar el nodo transmisor a un PC para comprobar, mediante el puerto serie, si la lectura de datos del GPS se realiza de forma correcta o si las tramas de información son almacenadas en la memoria interna del nodo, de manera adicional es necesario emplear un receptor LoRa para comprobar la prueba de envío de datos.

Las pruebas realizadas se detallan en los siguientes puntos:

- **Lectura del GPS.** Prueba: Conectar y leer las tramas de información de datos procedentes del GPS. Resultado: El nodo lee del GPS las tramas de información mostrando por pantalla tanto la trama leída directamente del GPS como la

trama procesada que se utilizará para el envío de datos y su almacenamiento. La boya deberá tener una autonomía eléctrica de 24 h y no constituir un peligro para la navegación.

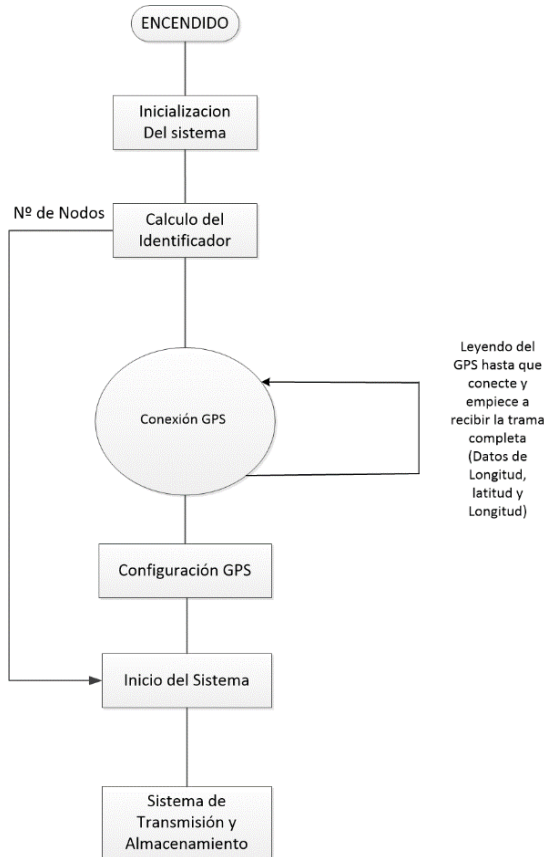


Figura 6 – Diagrama de flujo del programa del nodo transmisor.

- Almacenamiento de datos en el nodo transmisor. **Prueba:** Escribir en un fichero de texto dentro de la memoria interna del nodo receptor la trama de datos procedente del GPS. **Resultado:** Las distintas tramas quedan almacenadas en orden de escritura en un fichero de texto en la memoria interna del nodo, en la cual pueden ser leídas posteriormente.
- Envío de datos. **Prueba:** Transmitir por el enlace LoRa las tramas de datos GPS procesadas. **Resultado:** El nodo receptor recibe la información enviada vía LoRa y la muestra en una interfaz de consola.
- Autonomía. **Prueba:** Alimentar los nodos transmisores para que el sistema esté funcionando mientras no se agote la energía del acumulador. **Resultado:** Los nodos se encuentran en funcionamiento durante más de 24 horas, que es el requisito requerido.

4. Prototipo del nodo receptor

Se ha diseñado y ensamblado un prototipo del nodo receptor, que consta, básicamente, de un Gateway LoRa y un ordenador de tipo PC. Estos dos equipos se utilizarán en el puente de un buque de superficie y, en principio, no precisan de un recipiente estanco. Para el Gateway se ha seleccionado el dispositivo DRAGINO LG01-N formado por un Gateway LoRa de un solo canal y de código abierto, que permite conectar una red inalámbrica LoRa a una red con protocolo IP. En la Figura 7 se muestra una fotografía del dispositivo y en la Figura 8 el esquema de bloques proporcionado por el fabricante (DRAGINO, 2023).



Figura 7 – Fotografía del Gateway LoRa (DRAGINO, 2023)

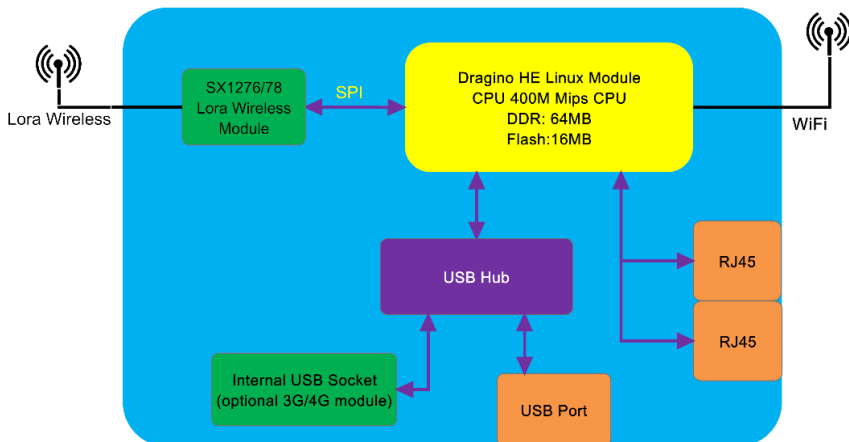


Figura 8 – Esquema de bloques del Gateway LoRa (DRAGINO, 2023).

El Gateway DRAGINO está basado en el microprocesador ar9331 a 400 MHz e incorpora una memoria flash de 16 MB y una memoria RAM de 64 MB. Su conexión al ordenador

tipo PC se realiza cómodamente a través de una red WiFi (se muestra esquemáticamente en la Figura 8), aunque también podría conectarse a través de uno de los puertos Ethernet (conector RJ45 en la Figura 8). El núcleo del Gateway es el router (bloque amarillo en la Figura) que sirve para multiplexar las comunicaciones de todos los terminales LoRa en un solo enlace ascendente (o saliente) y demultiplexar las comunicaciones del enlace descendente (o entrante) y enviar a cada terminal LoRa la que le corresponde. En la presente aplicación, este Gateway entrega al PC la información procedente de los nodos transmisores de manera que el PC puede extraer la enviada por cada uno de ellos. El Gateway elegido puede atender al menos 10 nodos LoRa y podría llegar a atender hasta 100 nodos; la cifra depende del volumen de datos que deba intercambiar con cada uno de ellos. En la aplicación de este proyecto se ha especificado que sean al menos 8. El Gateway se alimenta con 12 Vcc.

4.1. Software del nodo receptor

La programación del nodo receptor es relativamente más sencilla que la de los nodos transmisores, ya que consiste en recibir los mensajes LoRa, realizar una comparación y almacenarlos en la memoria interna del nodo. El diagrama de flujo de dicho programa se muestra en la Figura 9. Tras la inicialización del nodo, el receptor queda en modo escucha y cuando recibe una transmisión comprueba si se trata de una trama procedente de un nodo transmisor, en cuyo caso extrae los datos de la trama de acuerdo al formato ya explicado más arriba y los almacena en los ficheros independientes de cada uno de los nodos transmisores.

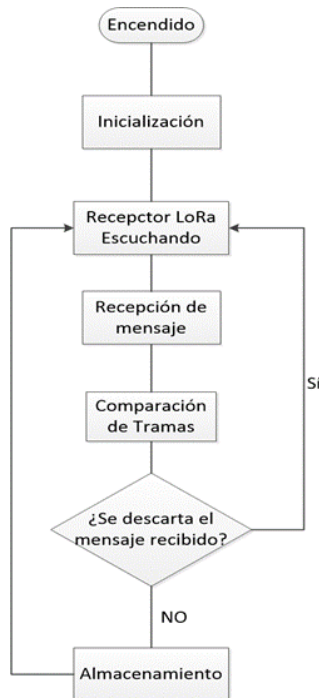


Figura 9 – Diagrama de flujo del programa del nodo receptor.

Pasemos a realizar las pruebas diseñadas para verificar el correcto funcionamiento del nodo receptor desarrollado en el proyecto. Estas pruebas están referidas a la recepción de mensajes vía LoRa, así como el almacenamiento interno en el Gateway y transferencia a un PC de dichos mensajes. Para estas pruebas es necesario conectar el nodo receptor (básicamente el Gateway Dragino LG01) a un PC mediante un enlace WiFi. Se utiliza el programa WinSCP (WinSCP, 2024) para transmitir ficheros entre el PC y el Gateway. WinSCP es una aplicación libre y de código abierto que implementa el protocolo SFTP (es un cliente SFTP) de intercambio de ficheros para el sistema operativo Windows.

Para validar el funcionamiento del nodo receptor se enviarán mensajes vía LoRa, desde distintos nodos, emulando el formato de las tramas de mensajes que enviarán los nodos transmisores. Las pruebas realizadas se detallan en los siguientes puntos:

- **Recepción de datos.** Prueba: Enviar mensajes LoRa desde diferentes nodos emulando el formato de la trama de datos que utilizará el sistema final. Resultado: Se muestran en la interfaz todos los mensajes recibidos en el formato correcto, ignorando el resto de los mensajes recibidos.
- **Almacenamiento de datos en el nodo receptor.** Prueba: Escribir los mensajes recibidos por LoRa en ficheros de texto independientes dentro de la memoria interna del nodo. Resultado: Se almacenan los datos de manera correcta en archivos de texto individuales en función del nodo transmisor de procedencia del mensaje gracias al id de la trama del mensaje.
- **Transferencia de los archivos al PC.** Prueba: Transferir los ficheros almacenados en la memoria del Gateway al PC mediante WinSCP. Resultado: Desde WinSCP se accede a la memoria interna del nodo y podemos transferir los distintos ficheros de la memoria interna al lugar deseado del PC conectado al nodo.

5. Pruebas de verificación y validación del sistema completo

Las pruebas finales se realizan con el sistema de seguimiento al completo: conjunto firmware/hardware de los nodos transmisor y receptor que incluyen los módulos GPS y el sistema de comunicación LoRa. Para ello, se distribuyen los nodos por diferentes zonas de una sala y se deja el sistema funcionando hasta que se agota la energía almacenada en los acumuladores. De esta forma verificamos y validamos el funcionamiento completo del sistema en un entorno real. Las pruebas realizadas se detallan en los siguientes puntos:

- **Envío de datos.** Prueba: Se pone en marcha el sistema con varios nodos transmisores funcionando, los cuales cada cierto tiempo procesarán los datos procedentes del GPS y enviarán la respectiva trama de datos empleando la tecnología LoRa. Las tramas deben de ser diferentes para cada transmisor ya que se encuentran colocados en sitios distintos y además cada uno de los nodos transmisores debe tener un ID único. Finalmente, en el nodo receptor podrán visualizarse las tramas recibidas en la interfaz de consola del PC. Salida: Los datos que llegan se muestran por pantalla y son almacenados en la memoria del nodo receptor. Verificación: Se comprueba la identificación correcta de cada nodo transmisor, la lectura de los datos del módulo GPS, el envío y recepción de datos, así como el funcionamiento de la interfaz de consola para mostrar los datos recibidos por el nodo receptor.

- **Identificación de datos.** Prueba: Se transferirán los ficheros almacenados en el nodo receptor utilizando un PC y WinSCP. Salida: En WinSCP se pueden ver que los datos se encuentran almacenados en diferentes ficheros de texto dentro del receptor y además transferir dichos datos al PC. Verificación: En esta prueba se verifica primero la identificación de los nodos transmisores, después el almacenamiento en el nodo receptor de las tramas recibidas por LoRa en diferentes archivos en función del código identificador del transmisor que aparece en la trama, y por último la transferencia de los datos almacenados en la memoria interna del nodo receptor a un PC.
- **Autonomía.** Prueba: Se medirá el tiempo que los nodos han estado funcionando desde que se encendieron hasta que se les haya acabado la energía del acumulador. Salida: Los datos almacenados en la memoria interna de los nodos transmisores acaban en el lugar previsto de la memoria del PC y pueden leerse en su pantalla, además los datos se almacenan una vez por minuto y a partir de dichos datos se obtiene el tiempo que han estado funcionando los distintos nodos transmisores. Verificación: Autonomía de los nodos transmisores ≥ 24 horas. Almacenamiento de la información y extracción de los datos almacenados en la memoria interna de los nodos transmisores.

6. Conclusiones y trabajos futuros

Se ha diseñado un sistema de seguimiento de boyas Lagrangianas y se han montado cuatro prototipos que se han instalado en unas maletas estancas que harán de continente de la boya. También se ha diseñado la vela para que la boya se desplace principalmente debido a la deriva. El objetivo del sistema era poder trazar las trayectorias de las boyas tras su recuperación después de 24 horas en el mar y, si un buque de superficie o simplemente un bote estaban dentro del alcance de un enlace LoRa, disponer de esa información en tiempo real. La tecnología LoRa no sólo permite el conocimiento en tiempo real de las trayectorias de las boyas, también ayuda a su localización para su recuperación, siempre y cuando se haga dentro del tiempo de autonomía de las boyas. El sistema cumple con los requisitos fijados de número de boyas, obtención de la posición, almacenamiento de las trayectorias, transmisión en tiempo real a un receptor que se encuentre dentro del alcance del enlace LoRa y almacenamiento de cada trayectoria en un ordenador de tipo PC. Las tareas pendientes son hacer pruebas de mar, es decir, desplegar las boyas en el mar y recuperarlas dentro del tiempo de autonomía, dictado por la energía eléctrica de los acumuladores de las boyas. Una vez comprobado el correcto funcionamiento de todo el sistema, se podrán integrar las trayectorias de las boyas en los procesos de asimilación de datos de los modelos numéricos que simulan la dinámica de las zonas interesadas por los experimentos lagrangianos.

Referencias

Adelantado, F., Vilajosana, X., Tuset-Peiro, P., Martinez, B., Melia-Segui, J., & Watteyne, T. (2017). Understanding the Limits of LoRaWAN. *IEEE Communications Magazine*, 55(9), 34–40. <https://doi.org/10.1109/MCOM.2017.1600613>

- DRAGINO (2023) LGO1-N--Single Channel LoRa IoT Gateway. <https://www.dragino.com/products/lora-lorawan-gateway/item/143-lgo1n.html>
- García-Ladona, E., Salvador, J., Fernández, P., Pelegrí, J. L., Elosegui, P., Sánchez, O., Jiménez Madrid, J. A., Pérez, F., Ballabrera, J., Isern-Fontanet, J., Salat, J., & Font, J. (2016). Thirty years of research and development of Lagrangian buoys at the Institute of Marine Sciences. *Scientia Marina*, 80(S1), 141–158. <https://dx.doi.org/10.3989/scimar.04325.14A>
- GitHub (2024) axp192. <https://github.com/usedbytes/axp192>
- GitHub (2024) esp32. <https://github.com/Inteform/esp32-lora-library>
- González-Palacio, M., Sepúlveda-Cano, L. M., Quiza-Montealegre, J., & D'Amato, J. (2020). Mejoramiento del algoritmo ADR en una red de Internet de las Cosas LoRaWAN usando Aprendizaje de Máquina. *RISTI - Revista Ibérica de Sistemas e Tecnologias de Informação*, (39), 68–93. <https://doi.org/10.17013/risti.39.67-83>
- Goursaud, C., & Gorce, J. M. (2015). Dedicated Networks for IoT: PHY/MAC State of the Art and Challenges. *EAI Endorsed Transactions on Internet of Things*, 15(1). <https://doi.org/10.4108/eai.26-10-2015.150597>
- ITU (2021) Recomendación UIT-T Y.4480 <https://www.itu.int/ITU-T/recommendations/rec.aspx?rec=14818&lang=es>
- LILYGO (2024) T-Beam SoftRF. <https://www.lilygo.cc/products/t-beam-softrf>
- LoRa (2024).LORA Alliance. <https://lora-alliance.org/>
- Link Labs (2016). A Comprehensive Look at Low Power, Wide Area Networks for Internet of Things Engineers and Decision Makers. <https://www.link-labs.com>
- Lumpkin, R., Özgökmen, T., & Centurioni, L. (2017). Advances in the Application of Surface Drifters. *Annual Review of Marine Science*, 9(1), 59–81. <https://doi.org/10.1146/annurev-marine-010816-060641>
- Martínez-Ledesma, M. (2011). Lagrangian buoys and drifters. Technical Report. Marine Electronics Laboratory. Marine Technologies, Operational Oceanography and Sustainability Department. Mediterranean Institute for Advanced Studies. <https://www.researchgate.net/publication/326839319>
- MITECO (2018). Súmate al Decálogo ciudadano contra las basuras marinas! <https://www.miteco.gob.es/es/ceneam/carpeta-informativa-del-ceneam/novedades/decalogo-basuras-marinas.html>
- Nilner, P. P., Sybrandy, A. S., Bi, K., Poulain, P. M., & Bitterman, D. (1995). Measurements of the water-following capability of holey-sock and TRISTAR drifters. *Deep Sea Research. Part I: Oceanographic Research Papers*, 42(11–12), 1951–1964. [https://doi.org/10.1016/0967-0637\(95\)00076-3](https://doi.org/10.1016/0967-0637(95)00076-3)
- Richardson, P. L. (2001). Drifters and Floats. In *Encyclopedia of Ocean Sciences*, 767–774. Elsevier Science. <https://doi.org/10.1006/rwos.2001.0305>

Sybrandy, A. L., & Niiler, P. P. (1991). The WOCE/TOGA SVP Lagrangian Drifter Construction Manual, 91(6) SIO reference, 63 WOCE report. Editor: University of California, San Diego, Scripps Institution of Oceanography.

SEMTECH (1960). What Is LoRa®?. <https://www.semtech.com/lora/what-is-lora>

SEMTECH(2024). Módem LoRa SX1278. <https://www.semtech.com/products/wireless-rf/lora-connect/sx1278#features>

Tipán-Alcívar, J. C., Párraga-Álava, J., & Herrera-Tapia, J (2022). Monitoreo de Niveles de Polución del Aire con Tecnología de Transmisión de Largo Alcance. RISTI – Revista Ibérica de Sistemas e Tecnologias de Informação, (E47), 157-170.

UE (2017). Base de datos FAOLEX. <https://www.fao.org/faolex/results/details/es/c/LEX-FAOC166390/>

WinSCP (2024). WinSCP. <https://winscp.net/eng/index.php>

Uma Aplicação para Explicabilidade de Predições de um SVM em Tweets de COVID-19

Ivo de Abreu Araújo¹, Renato Hidaka Torres², Nelson Cruz Sampaio Neto³

ivoabreu94@gmail.com; renatohidaka@ufpa.br; nelsonneto@ufpa.br

¹ Universidade Federal do Sul e Sudeste do Pará, 68638-000, Rondon do Pará – PA - Brasil

^{2,3} Universidade Federal do Pará - Faculdade de Computação, 66075-110, Belém – PA – Brasil

DOI: 10.17013/risti.54.121-137

Resumo: Este trabalho propõe uma aplicação web que usa um modelo de caixa preta *Support Vector Machine (SVM)* com 79% de acurácia para classificar o sentimento de *tweets* sobre a COVID-19 integrando o *framework LIME* de forma interativa para explicar decisões sobre previsões. Além do ganho de transparência em relação à avaliação de amostras falso-positivas, notou-se também que o modelo SVM tende a falhar ao associar um teste positivo de COVID-19 a um bom sentimento e se confunde em previsões envolvendo palavras sobre a COVID-19, como *Omicron*, que indica falta de representatividade na base de dados. Além disso, a partir dos resultados do *LIME*, foi possível melhorar a acurácia do modelo para 81% ao incluir as *stopwords* "not" e "no".

Palavras-chave: Processamento Natural de Linguagem; Framework de Explicabilidade; Explicabilidade de Modelos de Caixas Pretas; Aprendizado de Máquina.

An Application for Explicability of SVM Predictions on COVID-19 Tweets

Abstract: The present work proposes a web application that uses an Support Vector Machine (SVM) black box model with 79% accuracy to classify sentiment from tweets about COVID-19 integrating the LIME framework in an interactive way to explain decisions about predictions. Besides the gain in transparency in relation to the evaluation of false positive samples, it was also noted that the SVM model tends to fail when associating a positive COVID-19 test with a good sentiment and gets confused in specific predictions involving words related to COVID-19 variants such as Omicron, which indicate lack of representativeness in the database. In addition, from the LIME results, it was possible to improve the model accuracy to 81% by including the stopwords "not" and "no".

Keywords: Natural Language Processing; Explicability framework; Explicability of black box models; Machine learning.

1. Introdução

A pandemia causada pelo vírus SARS-CoV2 afetou o mundo e obrigou os países a tomarem decisões com o intuito de reduzir os consequentes impactos sociais, econômicos, culturais e políticos. Dentre as medidas tomadas, pode-se citar o isolamento social, que gerou como consequência uma maior interação das pessoas por meio das mídias sociais. Além disso, mídias sociais, como o Twitter, tornaram-se relevantes veículos de notícias e opiniões sobre a doença, bem como o uso de tecnologias para o apoio de processos estratégicos em setores da sociedade que gerenciam pessoas como turismo (Khan et al., 2020; López et al., 2023).

Com a imposição das restrições físicas, o uso de mídias sociais potencializou um envolvimento mais ativo de usuários com manifestações públicas por meio de mensagens de texto, que levou áreas como a de ensino a adaptarem seus profissionais a metodologias de ensino remotas, gerando assim uma base de dados onde é possível constatar experiências vividas pela população mundial em decorrência da COVID-19 (Aguayo et al., 2021).

Nessa perspectiva, Meena & Bai (2019) definem que as redes sociais são plataformas que propagam informações volumosas que permitem explorar e compreender sentimentos de indivíduos de uma sociedade. A análise dessas informações pode ajudar no desenvolvimento de ações que amenizem os problemas de saúde mental provocados pelas restrições da pandemia. De acordo com Recuero (2009), os termos rede social e mídia social são conceitualmente diferentes. Embora os sites de redes sociais atuem como suporte para as interações que constituirão as redes sociais, eles não são, por si, redes sociais. Assim, sistemas como o *Twitter* serão considerados mídias sociais, ou seja, um meio capaz de manter uma rede social ativa.

À vista disso, tem sido desafiador o uso de aplicações robustas de aprendizado de máquina na área de *NLP (Natural Language Processing)* para mapear opiniões e sentimentos diante de cenários inesperados, como o provocado pela COVID-19, com o intuito de adequar soluções inteligentes no âmbito de problemas sociais e psicológicos (Glowacki et al., 2021; Kolluri & Murthy, 2021).

Um dos atuais desafios em aprendizado de máquina é o uso de algoritmos com alta capacidade preditiva que são inerentemente não transparentes em suas decisões, uma vez que são considerados caixas pretas devido a complexidade que envolve suas funções internas (Molnar, 2019). Já o termo caixa branca é o oposto de caixa preta, pois, se refere a algoritmos que funcionam com base em estruturas mais simples de serem compreendidas pelo ser humano, por exemplo, a profundidade de uma árvore de decisão.

Dessa maneira, algoritmos de caixa branca garantem uma maior confiabilidade aos resultados preditivos. Nesse contexto, Nielsen (2020) define que a interpretabilidade de um algoritmo está diretamente relacionada com a compreensão do usuário quanto ao que o modelo decidiu em uma predição, por exemplo, os pesos de uma regressão linear, enquanto que a explicabilidade busca justificar como o modelo tomou uma decisão. Já Ahmad (2020) afirma que a explicabilidade de um algoritmo é desenvolvida pela capacidade qualitativa de identificar features que estão direta ou indiretamente

relacionadas a uma predição. Dado os conceitos apresentados, o presente artigo visa explorar a explicabilidade de um algoritmo de caixa preta.

Uma vez que medidas de tendência central, como *score* e *recall*, não são suficientes para um entendimento minucioso e explicativo de algoritmos de caixa preta (Ribeiro et al., 2016), *frameworks* de explicabilidade, como *LIME* (*Local Interpretable Model-Agnostic Explanations*) e *SHAP* (*Shapley Additive Explanations*), têm se popularizado. Esses *softwares* tentam explicar predições de modelos de aprendizado de máquina em contextos locais, explorando *features* com a finalidade de entender decisões internas de algoritmos de caixa preta (Lundberg & Lee, 2017).

Tendo em vista a importância de se compreender modelos de aprendizado de máquina mais robustos, principalmente aqueles que entregam soluções pouco transparentes, este artigo propõe estudar a explicabilidade do algoritmo de caixa preta *SVM* (*Support Vector Machine*) na tarefa de classificar sentimentos em textos coletados de uma mídia social. Uma análise sobre a ação de palavras vazias (ou *stopwords*, em inglês) na acurácia do modelo também é apresentada. Para isso, foi desenvolvida uma aplicação *web* no intuito de facilitar a interação com o *framework LIME*. A revisão bibliográfica realizada não encontrou trabalhos que explorassem o uso do *LIME* em tarefas de processamento de língua no *Twitter*.

Assim, o objetivo principal é classificar sentimentos em mensagens de usuários no *Twitter* sobre a COVID-19 e compreender a influência de certas palavras nas predições. O presente trabalho também busca responder as seguintes questões: O estudo da explicabilidade ajuda a determinar falta de representatividade na base de dados? A identificação de palavras mais ou menos influentes pode reduzir a ocorrência de predições falso-positivas? O uso de determinadas *stopwords* é capaz de melhorar a acurácia do modelo preditivo?

Os resultados obtidos demonstraram que a classificação de sentimentos de *tweets* sobre a COVID-19, agregada com a explicação da predição, possibilita a compreensão das palavras mais relevantes, mesmo quando o modelo treinado falha em classificar determinadas amostras. Outro destaque é a melhora de desempenho do modelo *SVM* após o uso de *stopwords*. Ao serem mantidas as palavras de negação “*not*” e “*no*” durante um novo processo de limpeza e treinamento da base de dados, a acurácia do modelo incrementou de 79% para 81%.

O restante do artigo encontra-se estruturado nas seguintes seções. A seção 2 apresenta trabalhos relacionados a pesquisa desenvolvida. A seção 3 trata do referencial teórico. A seção 4 descreve os materiais e métodos empregados. Na seção 5, os resultados são apresentados e discutidos. Por fim, a seção 6 traz as considerações finais e os trabalhos futuros.

2. Trabalhos relacionados

Esta seção apresenta uma descrição de estudos relacionados com análise de sentimentos e explicabilidade em aprendizado de máquina. É importante destacar que não foram encontrados artigos que seguiram a linha de pesquisa do presente trabalho, ou seja,

explicabilidade com o uso do *LIME* em *NLP*. O contexto escolhido foi a COVID-19 na mídia social *Twitter*.

Em Silva et al., (2021), é realizado um estudo na área de *NLP* no contexto de mensagens do *Twitter* relacionadas ao uso do serviço de saúde brasileiro durante a pandemia de COVID-19. A coleta dos dados ocorreu no período de dezembro de 2019 a outubro de 2020 por meio da ferramenta *Twint*. Para a classificação das mensagens, os autores utilizaram o classificador *NRC sentiment* com três classes: Positiva, Negativa e Neutra. Os resultados obtidos apresentaram um mapeamento de sentimentos durante cada mês do período de coleta dos dados, por exemplo, em fevereiro de 2019, houve uma predominância de sentimentos positivos, por conta das menções ao programa “Previne Brasil”. É interessante destacar que não houve o uso de um *framework* de explicabilidade para buscar entender quais termos eram mais importantes para a decisão da classificação.

Nessa mesma perspectiva, Garcia & Berton (2021) fizeram uma análise de sentimentos no *Twitter* em mensagens de texto do Brasil e dos EUA visando identificar opiniões sobre a pandemia de COVID-19. Classificadores de Regressão Logística, *Random Forest* e *SVM* foram comparados e obtiveram desempenhos similares na maioria dos testes realizados em uma base de dados coletada entre abril e agosto de 2020. Os resultados mostraram uma predominância de sentimentos negativos nas duas línguas no assunto de “cuidados com a proliferação do vírus”. Esse trabalho também não fez um estudo de explicabilidade sobre os modelos de caixa preta utilizados.

O artigo de Ayoub et al., (2021) apresentou um estudo de explicabilidade em mensagens falsas (ou *fakenews*, em inglês) coletadas na Internet e relacionadas a COVID-19. Para o desenvolvimento da pesquisa, os autores utilizaram o *framework SHAP* com o objetivo de entender o comportamento de um classificador *DistilBert*. O artigo reporta a identificação das palavras mais relevantes para a classificação de uma nova notícia e, por conseguinte, um melhor entendimento da lógica de decisão seguida pelo modelo, principalmente nos equívocos.

Seguindo na linha da explicabilidade, Liu et al., (2021) propõem um estudo para classificar sentimentos em mensagens do *Twitter* com temática plural e entender predições equivocadas de uma rede neural utilizando o *LIME*. A aplicação do *framework* permitiu ranquear as palavras mais influentes para a resposta do modelo e, assim, analisar as classificações que falharam. Além da explicabilidade local, os autores também consideraram a análise da explicabilidade global no seu estudo.

Em Behl et al., (2021), os autores realizaram uma análise de dados sobre situações emergenciais de desastres naturais. O artigo explorou a explicabilidade de um modelo *MLP (Multilayer Perceptron)* treinado em bases de dados referentes a terremotos no Nepal e na Itália com o objetivo de classificar as mensagens nas seguintes classes: “necessidade de ajuda”, “oferta de ajuda” e “outros”. Além dos testes realizados nessas bases de dados, o modelo também foi aplicado em mensagens de situações emergenciais da pandemia de COVID-19 no *Twitter*, resultando em 83% de acurácia para predições nas três classes mencionadas. Com relação a explicabilidade, o uso do *framework LIME* permitiu identificar as palavras mais importantes para a classificação do *MLP*.

Diferentemente dos artigos citados acima, que não dispõem de uma aplicação integrada, Kouvella et al., (2020) propõe um sistema *web* que usa o algoritmo de caixa preta *Random*

Forest para identificar usuários *bots* no *Twitter*. Para isso, o algoritmo foi treinado com uma base de dados contendo mensagens coletadas com a API do *Twitter*. Por fim, o *framework LIME* foi utilizado para gerar explicações em 20 *tweets* de cada perfil de usuário classificado pela caixa preta como legítimo ou *bot*.

3. Revisão da Literatura

Nos últimos anos, a explicabilidade tornou-se um fator importante quando o propósito é explorar comportamentos de predições em aprendizado de máquina, principalmente quando se trata do desafio de entender decisões de algoritmos de caixa preta em contextos em que a compreensão de resultados preditivos é essencial (Hall et al., 2021).

Nesse cenário, a inteligência artificial explicável, também conhecida como *XAI (Explainable Artificial Intelligence)*, complementa o conhecimento sobre decisões de algoritmos de uma maneira transparente com explicações compreensíveis no nível humano (Rothman 2020, Turek 2021).

Com relação à explicabilidade de aprendizado de máquina, Ahmad (2020) destaca dois tipos de abordagens importantes de serem compreendidas:

Explicabilidade local: Visa prover explicações mais minuciosas em pequenas regiões de um modelo, onde cada região diz respeito a uma amostra do *dataset*. Por exemplo, essa é a proposta do *framework LIME*, que gera explicabilidade apenas para uma amostra específica, haja vista que amostras individuais de um modelo são mais suscetíveis ao uso de regressões lineares do que toda a base de dados (Ribeiro et al., 2016).

Explicabilidade global: É interessante quando se busca uma visão completa do comportamento do modelo em predições. No entanto, esse tipo de explicação é mais complexa, considerando que a tarefa de encontrar relações entre as *features* com base no comportamento geral do modelo é mais desafiadora. Árvores de decisão e regressão linear são exemplos de algoritmos que inerentemente permitem serem compreendidos na sua totalidade.

3.1. Framework LIME

O *LIME* é uma solução de *framework* que tem se popularizado na área de aprendizado de máquina por explicar predições de qualquer modelo de aprendizado supervisionado. Conforme Ribeiro et al., (2016), o *LIME* tem como objetivo auxiliar desenvolvedores e usuários finais a compreenderem predições por meio de explicações baseadas em um modelo explicável.

O processo de explicação do *LIME* em *NLP* acontece localmente, ou seja, a partir de uma amostra específica escolhida pelo usuário. O *LIME* gera, aleatoriamente, amostras artificiais com o propósito de entender qual é o impacto de cada palavra presente no texto da amostra original. Para isso, cada nova amostra artificial tem como base o texto original, no entanto, com a remoção de algumas palavras.

Em seguida, o modelo de caixa preta (alvo da explicabilidade) realiza uma classificação para cada amostra artificial, verificando quais foram classificadas na mesma classe da amostra original e atribui um peso para cada palavra, baseado no seu impacto para a

saída do modelo. Por fim, o *LIME* aplica uma regressão linear (modelo substituto) para buscar explicar de forma aproximada a relação dos pesos de cada palavra com a predição da amostra original.

A função de explicação do *LIME* é dada por (1), otimizada para gerar a explicação mais próxima da predição original:

$$\xi(x) = \underset{g \in G}{\operatorname{argmin}} L(f, g, \pi x) + \Omega(g) \quad (1)$$

A explicação ξ dada pelo *LIME* para uma amostra x é obtida por um modelo substituto $g \in G$, onde G representa um conjunto de algoritmos explicáveis. Já $\Omega(g)$ diz respeito a complexidade do modelo substituto, ou seja, quanto mais baixa, maior a capacidade de explicabilidade a um nível humano. Por convenção, utiliza-se como modelo substituto uma regressão linear otimizada com uma função de erro $L(f, g, \pi x)$ que busca reduzir a complexidade da explicação, onde L é a função que minimiza o erro, por exemplo, uma regularização *Lasso*; f representa o modelo original, por exemplo, um *Random Forest*, que será explicado pelo *LIME*; e πx é a métrica que mede a proximidade entre as amostras artificiais geradas próximo da amostra original.

3.2. Métricas de Avaliação

Sobre a avaliação de desempenho dos algoritmos classificadores em aprendizado de máquina, o uso de alguns indicadores possibilita medir o nível de efetividade em predições. A seguir, são apresentadas as métricas citadas em [Kelleher et al. 2015]:

Acurácia: É considerada uma das métricas mais utilizadas, visto que é o resultado, em porcentagem, da divisão do número de amostras acertadas pelo total de amostras presentes no conjunto de teste.

Precisão: Avalia a quantidade de amostras positivas que o modelo acertou, considerando todas as amostras positivas e falso-positivas. À vista disso, há uma perspectiva e quão eficiente encontra-se o modelo para classificações que realmente eram positivas.

Revocação: Está relacionada ao nível de confiança que se pode obter do modelo em que, para o total de amostras positivas existentes (verdadeiramente positivas e falso-negativas), quantas realmente foram corretamente classificadas.

F-1 score: É a média harmônica entre a precisão e a revocação. Assim, quanto maiores forem os valores das métricas precisão e revocação, maior será o valor da F-1 score.

4. Materiais e Métodos

Nesta seção, são mostrados os recursos metodológicos utilizados no desenvolvimento de uma aplicação *web* que almeja facilitar o entendimento de um processo de categorização automático de sentimentos em *tweets* sobre a COVID-19. Todos os códigos desenvolvidos podem ser livremente acessados em (Araújo 2022^a).

4.1. Base de Dados

Este trabalho usou a base de dados desbalanceada disponibilizada por Miglani, (2020) contendo um total de 41.157 mensagens na língua inglesa, relacionadas a COVID-19, que foram extraídas do *Twitter* até dezembro de 2020 no formato *CSV (Comma Separated Values)*. O domínio de classificação é do tipo multiclases com cinco sentimentos: Positivo; Extremamente Positivo; Negativo; Extremamente Negativo; e Neutro.

Já que a base de dados possui uma quantidade significativa de mensagens, optou-se por não usar validação cruzada e nem particionamento dos dados. Segundo Shalev-Shwartz & Ben-David, (2014), as técnicas de validação cruzada são recomendadas principalmente quando há escassez de dados rotulados, fato que pode resultar em conjuntos de teste insuficientes para certificar a capacidade de generalização do modelo. Assim, a base de dados foi dividida em conjuntos de treino e teste, com 30.867 (75%) e 10.290 (25%) instâncias, respectivamente.

Das seis *features* originais (*username*, *screenname*, *local*, *tweetat*, *tweetoriginal* e sentimento), foram mantidas apenas as consideradas mais relevantes para o estudo: A *tweetoriginal* com o conteúdo da mensagem; e a sentimento, que é a classe alvo, com o rótulo do sentimento associado à mensagem.

4.2. Pré-processamento dos dados

Devido à similaridade entre as palavras relacionadas aos sentimentos positivo e extremamente positivo, buscou-se estabelecer fronteiras de explicação bem definidas entre as classes preditivas no intuito de facilitar o processo de explicabilidade. Dessa forma, todas as amostras positivas foram concentradas em uma “nova” classe chamada Positiva, ligada a expressões como felicidade, esperanca e interesse. O mesmo procedimento foi replicado para os exemplos negativos, que foram juntados na classe Negativa, associada a expressões como tristeza, caos e fraqueza. Assim, tem-se três classes para uma predição: Positiva (18.046 amostras); Negativa (15.398 amostras); e Neutra (7.713 amostras).

Na tentativa de reduzir inconsistências, os seguintes procedimentos de *NLP* foram realizados no conteúdo das mensagens: Remoção de URLs, HTMLs, caracteres especiais, espaços e números; e conversão de todas as palavras para minúsculo. Nessa etapa, *scripts* da biblioteca *Scikit-learn*, versão 0.24.1, foram usados para realizar as ações.

Em seguida, aplicou-se o método de *stopwords*, que consiste na remoção de palavras irrelevantes, como artigos e conjunções, as quais são frequentes, mas não implicam na compreensão da semântica de uma sentença (Bonaccorso, 2017). Para isso, este trabalho fez uso da biblioteca *NLTK (Natural Language Toolkit)*, versão 3.4.5, com uma lista de *stopwords* (Araújo, 2022c) contendo 179 palavras que, por convenção, são tratadas como irrelevantes na língua inglesa.

A etapa final de preparação dos dados tratou da tokenização, ou seja, processo que divide um texto em palavras transformado-as em um vetor de inteiros, com números que representam a frequência de cada palavra (Hapke et al., 2019).

4.3. Classificação de sentimentos

Para a etapa de classificação, foram utilizados três algoritmos: *SVM*, *Random Forest*; e *RNAR (Rede Neural Artificial Rasa)*. Esses métodos foram escolhidos por serem caracterizados na literatura como caixas pretas e não transparentes. Dessa maneira, o objetivo foi comparar o desempenho de cada um e escolher o mais preciso.

O *Random Forest* foi configurado com base no conjunto padrão de hiperparâmetros com 100 árvores. Com relação ao *SVM*, também optou-se pela utilização das especificações padrões, com a definição de uma função de *kernel* do tipo linear. Sobre a *RNAR*, empregou-se uma arquitetura baseada em Lad, (2020), sendo uma rede do tipo *feed-forward*, configurada com cinco camadas, totalizando 127 neurônios e 381.265 parâmetros treinados com 50 épocas.

Ao comparar os resultados obtidos pelos três algoritmos no conjunto de teste, optou-se pelo *SVM*, em função desse algoritmo ter se mostrado superior em todas as métricas convencionais: acurácia (79%), precisão (77%), *F-1 score* (78%) e revocação (78%). Assim, o modelo *SVM* foi utilizado na aplicação *web* e nos experimentos descritos a seguir.

4.4. Aplicação web

O desenvolvimento de uma aplicação *web* integrada com o *framework LIME* se justifica ao agilizar o processo de predição e explicação de novas amostras. A ferramenta proposta oferece acessibilidade online para estudos de explicabilidade e exploração do comportamento de algoritmos de caixa preta, tanto por especialistas em aprendizado de máquina, quanto por usuários de aplicações em produção. É destacável também que, para eventuais atualizações de modelo ou aplicação, há um ganho no reuso da arquitetura criada.

Dito isto, para a construção da aplicação *web*, denominada *Twitter COVID Explainer*, utilizou-se uma arquitetura de *software* cliente-servidor por meio da *API do Flask*, que dispõe de bibliotecas que permitem criar soluções integradas com *Python*. A arquitetura da ferramenta é ilustrada na Figura 1.




Figura 1 – Arquitetura da aplicação *web*.

Inicialmente, o usuário fornece como entrada a mensagem que deseja categorizar e a quantidade de palavras (20 termos no máximo) a serem ranqueadas de acordo com o seu nível de importância para o processo preditivo. Em seguida, a mensagem é pré-

processada, transformada em um vetor de inteiros e classificada pelo modelo SVM. A última etapa consiste na explicação da predição por meio do *framework LIME*, mais especificamente, usou-se o módulo *LimeTextExplainer*, versão 0.2.0.1. A página inicial da aplicação, que encontra-se publicamente disponível em (Araújo 2022b), pode ser visualizada na Figura 2.

O resultado da predição de um *tweet* classificado corretamente pelo modelo SVM como um sentimento positivo pode ser visto na Figura 3, evidenciando as probabilidades.

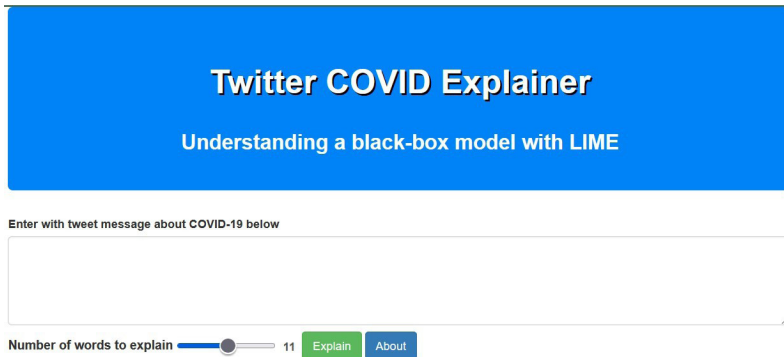


Figura 2 – Tela inicial da aplicação *web*. O usuário insere um *tweet* e define a quantidade de palavras a serem explicadas. Fonte: Elaborada pelo autor.

de cada classe e o gráfico de explicação do *LIME* configurado para mostrar as 10 palavras mais relevantes para a predição do *tweet*. Nesse exemplo, apenas três palavras (destacadas na cor verde) influenciaram positivamente a predição. Já as outras expressões foram consideradas influentes para as demais classes. É possível observar que a palavra “*free*” foi considerada a mais importante pelo modelo, adicionando uma probabilidade de 49% para o sentimento positivo.

Twitter Message: Book your free flu or COVID-19 vaccine on #BoostDay for maximum protection while spending time with loved ones this festive season

SVM Classification: Positive sentiment

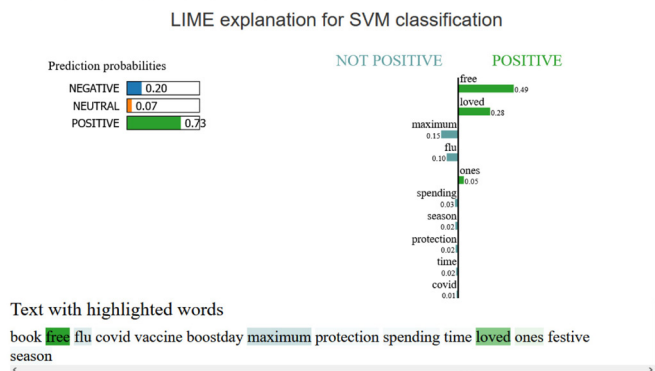


Figura 3 – Resultado da classificação correta de um tweet com sentimento positivo.

5. Resultados

Esta seção descreve os testes realizados com a aplicação *Twitter COVID Explainer*. A ideia central dos experimentos foi de avaliar a explicabilidade de forma qualitativa, observando o efeito de certas palavras nas predições.

5.1. Predições falso-positivas

Inicialmente, 30 mensagens do *Twitter* na língua inglesa relacionadas ao tema COVID-19 foram aleatoriamente selecionadas entre os anos de 2021 e 2022. Em seguida, esses *tweets* foram manualmente rotulados: 15 negativas, 11 positivas e 4 neutras. Lembrando que a base de dados usada no treinamento dos modelos foi coletada até o ano de 2020.

A explicação de uma predição falso-positiva para uma mensagem que na realidade corresponde a um sentimento negativo, devido ao aumento de pessoas que testaram positivo para COVID-19, pode ser vista na Figura 4. Observa-se, claramente, que a palavra “positive” influenciou fortemente o modelo a classificar a mensagem como sentimento positivo.

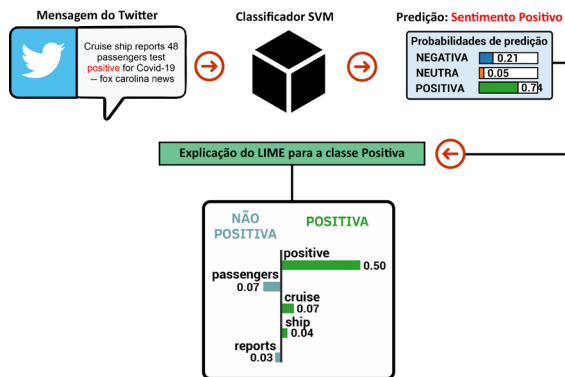


Figura 4 – Resultado da aplicação *web* configurada para explicar cinco palavras de um tweet classificado equivocadamente como sentimento positivo.

No intuito de validar o entendimento, a palavra “*positive*” foi removida da mensagem, a predição refeita e, como esperado, a classificação foi corretamente corrigida para negativa. É evidente que a remoção da palavra citada reduz a semântica da mensagem, no entanto, o objetivo do experimento foi atestar que o modelo diminui a certeza para uma mensagem falso-positiva e classifica corretamente o *tweet*. A base de dados contempla poucos exemplos (menos de 1% das mensagens) envolvendo testes de COVID-19. Tendo acesso a esse tipo de informação, o especialista pode otimizar a base de dados na tentativa de mitigar essa falta de representatividade.

Outro exemplo de limitação encontrado refere-se a palavra “vacina”. Como a coleta dos dados ocorreu em 2020, período que antecede a popularização de expressões como vacinas e variantes, foram encontradas apenas 139 amostras com esses termos, o que

corresponde a menos de 1% do total. Por exemplo, na Figura 5, em que a mensagem do *Twitter* relata que o reforço de vacinas é importante (algo que é positivo), o modelo classificou o *tweet* como sentimento negativo. Nota-se que a palavra “vacina” foi considerada pouco influente na predição e a palavra “Omicron”, que corresponde a uma variante de COVID-19, sequer foi considerada.

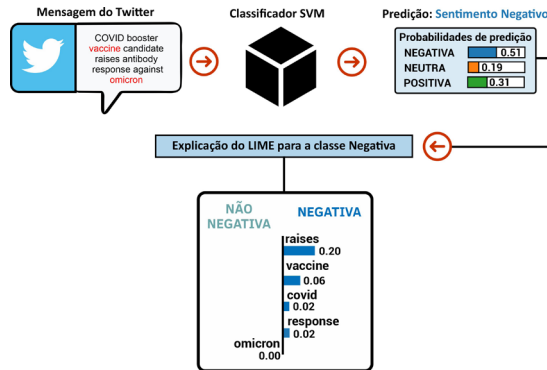


Figura 5 – Resultado da aplicação *web* configurada para explicar cinco palavras de um *tweet* classificado equivocadamente a respeito do termo vacina.

5.2. Stopwords

Esta etapa dos experimentos estudou o efeito que a retirada das *stopwords*, ou seja, palavras que podem ser consideradas irrelevantes para o conjunto de resultados a ser exibido, tem sobre o processo de classificação. Para isso, se escolheu as *stopwords* “no” e “not” com a hipótese que elas podem ajudar a influenciar negativamente uma sentença. A palavra “no” ocorre em 2.300 amostras (5,5%) e a palavra “not” em 5.489 amostras (13,3%). Um exemplo de amostra formatada e corretamente classificada pode ser visto na Figura 6.

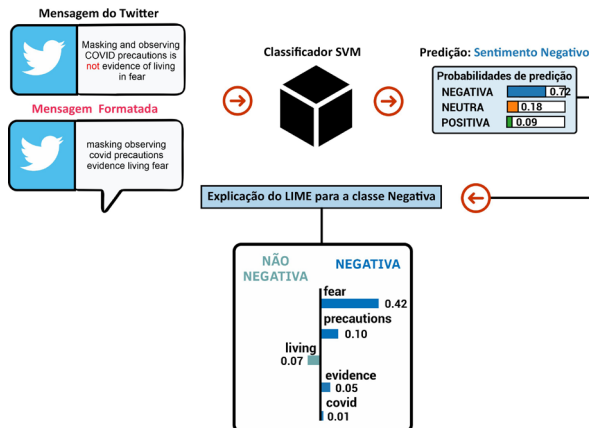


Figura 6 – Resultado da aplicação *web* para a classificação de uma mensagem com sentimento negativo explicada pelo *LIME*.

As palavras “not” e “no” foram, então, mantidas em todas as amostras e os modelos SVM, RNAR e Random Forest (RF) retreinados. Os resultados das duas avaliações, com e sem as stopwords analisadas, podem ser comparados na Tabela 1. Nota-se um ganho em todas as métricas, por exemplo, a acurácia do classificador SVM que passou de 79% para 81%. Contudo, o teste estatístico não paramétrico de Kolmogorov-Smirnov mostrou que os modelos com e sem stopwords não possuem diferença significativa (p-value = 0,92). Outras métricas de desempenho, como precisão e revocação, que tratam da assertividade com relação às amostras falso-positivas e falso-negativas, também melhoraram, mas não significativamente.

Treino	Modelo	Stopwords “no” e “not”	Acurácia	Precisão	F1-Score	Revocação
1	SVM	Removidas	79%	77%	78%	78%
2	SVM	Incluídas	81%	79%	79%	80%
1	RF	Removidas	74%	73%	74%	73%
2	RF	Incluídas	77%	75%	76%	76%
1	RNAR	Removidas	72%	71%	69%	70%

Tabela 1 – Resultados obtidos com os algoritmos considerando a remoção e a inclusão das palavras “no” e “not”.

A mesma sentença usada na Figura 6 foi novamente classificada, mas, dessa vez, usando o modelo SVM retreinado e preservando a palavra “not”. A explicação do framework LIME pode ser vista na Figura 7. Nota-se que o classificador passou a considerar a palavra “not” no processo preditivo, sendo a segunda mais influente, e ratificou o sentimento negativo da sentença, no entanto, com mais convicção.

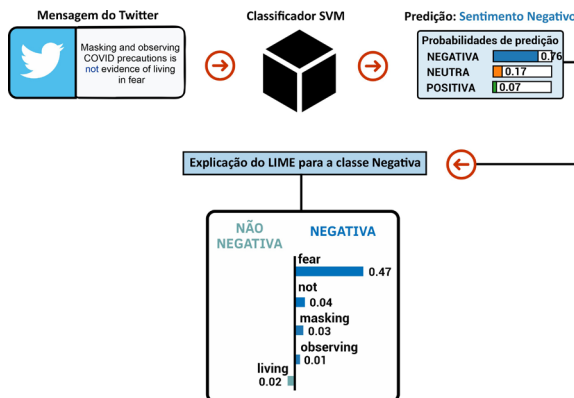


Figura 7 – Resultado da aplicação web para a classificação de uma mensagem com sentimento negativo com a palavra “not” tendo influência na predição.

Um exemplo de classificação onde a palavra “no” influenciou fortemente a predição para a classe negativa pode ser vista na Figura 8. Antes do retreino, essa mesma sentença

(sem a *stopword* em questão) havia sido classificada equivocadamente como neutra. Evidentemente, as palavras “not” e “no” são irrelevantes em determinados contextos da língua inglesa e uma explicação local não implica em um comportamento semelhante para todas as amostras.

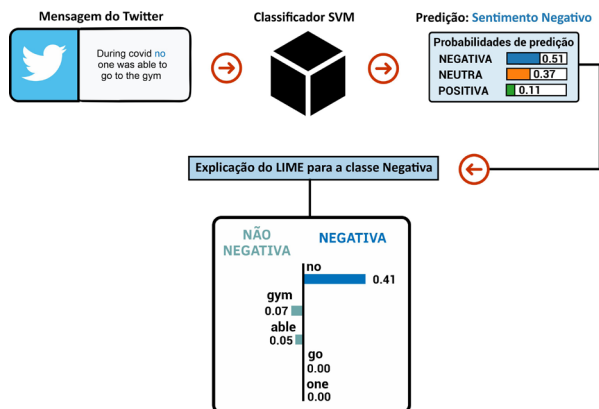


Figura 8 – Resultado da aplicação web para a classificação de uma mensagem com sentimento negativo com a palavra “no” tendo influência na predição.

O uso de um classificador inteligente acompanhado de um *framework* de explicabilidade, como o *LIME*, trouxe mais transparência e novas possibilidades de exploração para as predições realizadas. Em estudos na área de *NLP*, a validação das *stopwords* é uma etapa importante dentro do processo preditivo. Por fim, constatou-se que, em mensagens curtas, o *LIME* se mostrou pouco útil, talvez por não conseguir encontrar uma representação linear capaz de explicar adequadamente as relações entre as palavras.

6. Conclusões e trabalhos futuros

Este estudo permitiu constatar a importância de se compreender melhor o trabalho de algoritmos mais robustos como os do tipo caixa preta em soluções de aprendizado de máquina, onde há o dilema: transparência versus alto desempenho.

O uso da explicabilidade mostrou ausência de representatividade (desatualização) na base de dados. Em certas predições falso-positivas, notou-se que palavras julgadas relevantes e atuais não estavam sendo realcioadas pelo *LIME* em função do surgimento de novos termos com o avanço da pandemia da COVID-19. A análise da explicabilidade também possibilitou identificar palavras mais ou menos influentes, fato que contribuiu para ajustes no modelo com o objetivo de reduzir a ocorrência de predições falso-positivas.

Sobre a hipótese que o uso de *stopwords* pode aumentar a acurácia do modelo, observou-se que a predição das amostras com sentimento negativo melhorou com a adição das palavras “no” e “not” nas mensagens. A acurácia do classificador *SVM*, por exemplo,

passou de 79% para 81%. Embora essa diferença não seja estatisticamente significativa, em temas sensíveis qualquer melhora preditiva pode ser importante.

A integração de um *framework* de explicabilidade, como o *LIME*, a uma aplicação de aprendizado de máquina para tarefas de *NLP* agregou transparência e possibilitou alcançar resultados mais esclarecedores e qualitativos sobre o modelo, complementando as métricas de avaliação quantitativas convencionais. Dessa maneira, usuários comuns e profissionais da área têm a sua disposição um panorama da representatividade da base de dados e de como palavras-chave podem contribuir para uma predição, seja ela assertiva ou equivocada.

Com relação aos trabalhos futuros, sugere-se a inclusão de dados mais atuais sobre a COVID-19, de modo a melhorar a generalização do modelo *SVM* para novos vocabulários. Ainda na linha de pesquisa deste trabalho, comparar o processo preditivo de outros algoritmos de caixa preta, como *Random Forest* e *RNAR*, usando diferentes *frameworks* de explicabilidade, como o *SHAP*. Também seria interessante a realização de mais estudos sobre stopwords e explicabilidade em outros idiomas, por exemplo, a língua portuguesa.

Referências

- Aguayo, R., Lizarraga, C., López-Bojórquez, M., Quiñonez, Y., & Cabrera, A. (2022). Implementación de plan de contingencia ante la pandemia covid-19 llamado rompiendo paradigmas docentes. *RISTI - Revista Ibérica de Sistemas e Tecnologias de Informação*, (45),48–63. <https://doi.org/10.17013/risti.45.48-63>
- Ahmad, I. (2020). 40 Algorithms every programmer should know: Hone your problem-solving skills by learning different algorithms and their implementation in python.
- Araújo, I. (2022a). Códigos de nlp. <https://github.com/ivoaabreu/dissertacao-mestrado-ufpa-codigos-nlp>
- Araújo, I. (2022b). Endereço da aplicação web. <https://twitter-explainer.onrender.com>
- Araújo, I. (2022c). Lista de stopwords. <https://github.com/ivoaabreu/dissertacao-mestrado-ufpa-codigos-nlp-lime/blob/main/lista-stop-words.pdf>
- Ayoub, J., Yang, X. J., & Zhou, F. (2021). Combat covid-19 infodemic using explainable natural language processing models. *Information Processing & Management*, 58(4):102569. <https://doi.org/10.1016/j.ipm.2021.10256>
- Behl, S., Rao, A., Aggarwal, S., Chadha, S., & Pannu, H. (2021). Twitter for disaster relief through sentiment analysis for covid-19 and natural hazard crises. *International Journal of Disaster Risk Reduction*, 55,102101. <https://doi.org/10.1016/j.ijdrr.2021.102101>
- Bonaccorso, G. (2017). *Machine learning algorithms*. Packt Publishing Ltd.
- Garcia, K. & Berton, L. (2021). Topic detection and sentiment analysis in twitter content related to covid-19 from brazil and the USA. *Applied Soft Computing*, 101:107057. <https://doi.org/10.1016/j.asoc.2020.107057>

- Glowacki, E. M., Wilcox, G. B., & Glowacki, J. B. (2021). Identifying# addiction concerns on twitter during the covid-19 pandemic: A text mining analysis. *Substance abuse*, 42(1),39–46. <https://doi.org/10.1080/08897077.2020.1822489>
- Hall, P., Gill, N., & Cox, B. (2021). Responsible machine learning.
- Hapke, H., Howard, C., & Lane, H. (2019). *Natural Language Processing in Action: Understanding, analyzing, and generating text with Python*. Simon and Schuster.
- Kelleher, J. D., Mac Namee, B., & D’arcy, A. (2015). *Fundamentals of machine learning for predictive data analytics: algorithms, worked examples, and case studies*. MIT press.
- Khan, R., Shrivastava, P., Kapoor, A., Tiwari, A., & Mittal, A. (2020). Social media analysis with ai: sentiment analysis techniques for the analysis of twitter covid-19 data. *J. Crit. Rev.*, 7(9),2761–2774.
- Kolluri, N. L. & Murthy, D. (2021). Coverifi: A covid-19 news verification system. *Online Social Networks and Media*, 22,100123. <https://doi.org/10.1016/j.osnem.2021.10012>
- Kouvela, M., Dimitriadis, I., & Vakali, A. (2020). Bot-detective: An explainable twitter bot detection service with crowdsourcing functionalities. In *Proceedings of the 12th International Conference on Management of Digital EcoSystems*, pp. 55–63. <https://doi.org/10.1145/3415958.3433075>
- Lad, R. (2020). *Parkinson’s disease classification*. Disponível em <https://www.kaggle.com/richalad/parkinsons-predictions>
- Liu, Z., Guo, Y., & Mahmud, J. (2021). When and why does a model fail? a human-in-the-loop error detection framework for sentiment analysis. <https://doi.org/10.48550/arXiv.2106.00954>
- López, M. P. V., de Freitas, P. O., & Vargas, S. M. L. (2023). A relação entre a inovação tecnológica e o desempenho nos meios de hospedagem no contexto da pandemia da covid-19. *RISTI - Revista Ibérica de Sistemas e Tecnologias de Informação*, (52),45–60. <https://doi.org/10.17013/risti.52.45-60>
- Lundberg, S. M., & Lee, S.-I. (2017). A unified approach to interpreting model predictions. In *Advances in neural information processing systems*, pp. 4765–4774.
- Meena, R. & Bai, V. T. (2019). Study on machine learning based social media and sentiment analysis for medical data applications. In *2019 Third International conference on I-SMAC (IoT in Social, Mobile, Analytics and Cloud)(I-SMAC)*, pp. 603–607. IEEE. <https://doi.org/10.1109/I-SMAC47947.2019.9032580>
- Miglani, A. (2020). *Coronavirus tweets nlp - text classification*. <https://www.kaggle.com/sagarkhambad/text-classification/data>
- Molnar, C. (2019). *Interpretable machine learning: A Guide for Making Black Box Models Explainable*. Leanpub.
- Nielsen, A. (2020). *Practical Fairness*. O’Reilly Media.

- Recuero, R. (2009). Redes sociais na internet, difusão de informação e jornalismo: elementos para discussão. *Metamorfoses jornalísticas*, 2,1–269.
- Ribeiro, M. T., Singh, S., & Guestrin, C. (2016). "why should i trust you?" explaining the predictions of any classifier. In *Proceedings of the 22nd ACM SIGKDD international conference on knowledge discovery and data mining*, pp. 1135–1144. <https://doi.org/10.1145/2939672.2939778>
- Rothman, D. (2020). *Hands-On Explainable AI (XAI) with Python: Interpret, visualize, explain, and integrate reliable AI for fair, secure, and trustworthy AI apps*. Packt Publishing Ltd.
- Shalev-Shwartz, S. & Ben-David, S. (2014). *Understanding machine learning: From theory to algorithms*. Cambridge university press.
- Silva, H., Andrade, E., Araújo D., & Dantas, J. (2021). Sentiment analysis of tweets related to sus before and during covid-19 pandemic. *IEEE Latin America Transactions*, 20(1),6–13. <https://doi.org/10.1109/TLA.2022.9662168>
- Turek, M. (2021). Explainable artificial intelligence.
- Redondo, A. M. F., & Cárdenas, F. de J. N. (2022). DevOps: Un vistazo rápido. *Ciencia Huasteca Boletín Científico de la Escuela Superior de Huejutla*, 10(19), 35-40.

Crítérios Editoriais

A RISTI (Revista Ibérica de Sistemas e Tecnologias de Informação) é um periódico científico, que foca a investigação e a aplicação prática inovadora no domínio dos sistemas e tecnologias de informação.

O Conselho Editorial da RISTI incentiva potenciais autores a submeterem artigos originais e inovadores para avaliação pelo Conselho Científico.

A submissão de artigos para publicação na RISTI deve realizar-se de acordo com as chamadas de artigos e as instruções e normas disponibilizadas no sítio Web da revista (<http://www.risti.xyz/>).

Todos os artigos submetidos são avaliados por um conjunto de membros do Conselho Científico, não inferior a três elementos.

Em cada número da revista são publicados entre cinco a oito dos melhores artigos submetidos.

Críterios Editoriales

La RISTI (Revista Ibérica de Sistemas y Tecnologías de la Información) es un periódico científico, centrado en la investigación y en la aplicación práctica innovadora en el dominio de los sistemas y tecnologías de la información.

El Consejo Editorial de la RISTI incentiva autores potenciales a enviar sus artículos originales e innovadores para evaluación por el Consejo Científico.

El envío de artículos para publicación en la RISTI debe hacerse de conformidad con las llamadas de los artículos y las instrucciones y normas establecidas en el sitio Web de la revista (<http://www.risti.xyz/>).

Todos los trabajos enviados son evaluados por un número de miembros del Consejo Científico de no menos de tres elementos.

En cada número de la revista se publican cinco a ocho de los mejores artículos enviados.



Revista Ibérica de Sistemas e Tecnologias de Informação
Revista Ibérica de Sistemas y Tecnologías de Información

©RISTI 2024 <http://www.risti.xyz>

